
Nutzung von Texturinformationen
hochaufgelöster SAR-Daten zur
Beschreibung von Siedlungsflächen

Dissertation

zur Erlangung des akademischen Grades doctor rerum naturalium
(Dr. rer. nat.)

vorgelegt dem Rat der Chemisch-Geowissenschaftlichen Fakultät der
Friedrich-Schiller-Universität Jena

von Dipl. Umweltwiss., Michael Thiel,
geboren am 09.08.1973 in Mettendorf.

Gutachter:

1. Prof. Dr. Christiane Schmullius, Universität Jena
2. Prof. Dr. Christopher Conrad, Universität Würzburg

Tag der öffentlichen Verteidigung: 23.01.2013

Kurzfassung

Als Zentren der menschlichen Entwicklung unterliegen Siedlungsräume steten sozioökonomischen, ökologischen wie auch strukturellen Veränderungen. Im Hinblick auf die zunehmende Verstädterung beeinflussen derartige Veränderungen die Lebensqualität immer größerer Bevölkerungsteile. Daher kommt dem Monitoring von Siedlungsräumen und deren Veränderung eine große Bedeutung zu. Die satellitengestützte Fernerkundung hat sich dabei in den letzten Jahren zunehmend als wertvolles Instrument erwiesen. Sie ist in der Lage rasch und mit vergleichsweise geringen Kosten planungsrelevante Informationen zum Ist-Zustand eines Siedlungsraums zu liefern. Mit Blick auf dieses Potential können neuartige Radarsensoren zudem eine hohe Datensicherheit gewährleisten. So ist die TerraSAR-X/TanDEM-X Mission, auf deren Daten in der vorliegenden Dissertation das Hauptaugenmerk liegt, in der Art konzipiert, dass in einem Zeitraum von zwei Jahren eine doppelte Abdeckung der Erdoberfläche mit hoher Auflösung erreicht wird. So ist das übergeordnete Ziel der vorliegenden Dissertation zu untersuchen inwiefern sich Siedlungsräume und deren Umfeld anhand neuartiger automatisierbarer Methoden auf Grundlage einfach polarisierter SAR-Daten und daraus abgeleiteter Informationen erfassen und bewerten lassen.

Die entwickelten Methoden beinhalten pixelbasierte und objektorientierte Verfahren in denen die Klassenentscheidung auf einfachen Schwellwertverfahren aufsetzt. Die Hauptentwicklungen zielen auf der Abgrenzung bebauter Flächen von deren Umland. Damit wird der Grundstein zu einem SAR-basierten Monitoring von Stadtausbreitungen gelegt. In einem ersten Schritt wird dabei ein objektorientiertes Verfahren entwickelt, das neben den Intensitätsinformationen des TerraSAR-X auch aus diesen abgeleitete Texturinformationen auswertet. Auf den Erkenntnissen dieser Entwicklung baut in einem nächsten Schritt die Entwicklung eines pixelbasierten Verfahrens zur Erfassung bebauter Flächen auf. Der Vorteil dieses unüberwachten, pixelbasierten Verfahrens gegenüber dem objektorientierten liegt in der Reduzierung der Rechenzeit und der damit verbundenen besseren Eignung zur automatisierten Anwendung auf große Datenmengen. Die Robustheit der pixelbasierten Methode kann anhand intensiver Tests zur Übertragbarkeit im Raum, in der Zeit und auf weitere TerraSAR-X Datenprodukte nachgewiesen werden. Das Resultat der Übertragung auf L-Band SAR

fällt hingegen unbefriedigend aus.

Nachfolgende Untersuchungen konzentrieren auf einer weitergehenden Bewertung von Siedlungsarealen und deren Umfeld. In Anlehnung an ältere Untersuchungen werden dabei die Klassen 'Siedlungsraum', 'Wald', 'Offenland' und 'Wasser' klassifiziert. Die Verteilung dieser Klassen im Bereich von Siedlungsräumen hat einen großen Einfluss auf das Mikroklima. So können Wälder der Frisch- und Kaltluftzufuhr dienen, während Gewässer als Energiespeicher fungieren. Die entwickelte Methodik wird dabei auf ihr Potential bezüglich der Klassifikationsgenauigkeit und Automatisierbarkeit getestet. Die erzielten Ergebnisse können durchweg als zufriedenstellend bezeichnet werden. Somit wird ein Verfahren zum Monitoring des aktuellen Zustands sowie Veränderungen der Landbedeckung im Siedlungsbereich bereitgestellt.

Die abschließenden Untersuchungen konzentrieren sich auf eine detailliertere Charakterisierung des Siedlungsraums. Diese sind durch Kleingliedrigkeit und eine hohe Dynamik gekennzeichnet. In besonderem Maße treffen diese Attribute auf Baugebiete zu, sie repräsentieren die Entwicklungen des Siedlungsraums. Die Untersuchungen basieren auf der Annahme, dass sich Baugebiete, aufgrund der Bautätigkeiten, über etablierte Verfahren zur Veränderungsanalyse erfassen lassen. Neben Baugebieten sind im Siedlungsraum jedoch auch andere Flächen auszumachen, die regelmäßigen Veränderungen unterliegen, z. B. Parkplätze, Straßen, u. a. Diese Areale lassen jedoch im Vergleich mit Baugebieten eine geringere Heterogenität in der SAR Aufnahme erwarten. Dementsprechend wird untersucht, mit welcher Güte sich Baugebiete von anderen Flächen mit Veränderung anhand eines schwellwertbasierten Verfahrens über Texturmaße trennen lassen. Damit soll ein erster Eindruck über die Möglichkeiten einer weitergehenden Charakterisierung von Siedlungsräumen erhalten werden. Die erzielten Resultate sind vielversprechend. In zwei von drei regulären Zeitschnitten konnten sehr gute Klassifikationsergebnisse erzielt werden.

Mit den vorgenommenen Entwicklungen konnte ein Grundstein zum X-Band basierten Monitoring von Siedlungsräumen und deren Umfeld gelegt werden. Es können Informationen über die Ausbreitung der Bebauung, sowie über einige das urbane Mikroklima beeinflussende Faktoren, Bewaldung und Wasserflächen, gewonnen werden. Verbunden mit der Planung der TerraSAR-X/TanDEM-X Mission sowie der hohen Datensicherheit der Mikrowellen-Fernerkundung deutet sich das Potential zu einer Inventarisierung der weltweiten Siedlungsflächen an.

Danksagung

Diese Arbeit entstand in weiten Teilen während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Fernerkundung der Universität Würzburg und ist eng mit meinen Projektarbeiten im Zuge der Nutzungsvorbereitung für TerraSAR-X Daten zu sehen. Vorab möchte ich allen danken, die zum Entstehen dieser Dissertationsschrift beigetragen haben.

Wie so häufig gibt es eine Person, ohne die diese Arbeit in der vorliegenden Art nicht hätte vorgenommen werden können. In diesem Fall ist es Dr. Thomas Esch, dessen Forschungen den Grundstein zu dieser Arbeit legten und der mir immer ein zuverlässiger und kompetenter Diskussionspartner und Mentor war. Seine unerschöpflichen Fähigkeiten, Freude an noch so quälenden Arbeitsprozessen zu vermitteln, waren mir eine große Hilfe.

Ein besonderer Dank gilt Frau Prof. Dr. C. Schmullius für die Begutachtung der Arbeit und die Hinweise zur Fertigstellung der Dissertationsschrift sowie Prof. Dr. C. Conrad für die Zweitbegutachtung und die Bereitstellung der Infrastruktur am Lehrstuhl für Fernerkundung der Universität Würzburg.

Ganz herzlich danken möchte ich allen aktuellen und ehemaligen Mitarbeitern sowie studentischen Hilfskräften des Lehrstuhls für Fernerkundung der Universität Würzburg, mit denen ich zusammenarbeiten und diskutieren durfte. Gute Kollegen sind die Grundvoraussetzung für funktionierende Teamstrukturen und ein angenehmes Forschungsklima. Gleiches gilt für das Team *Siedlungsraum und Landmanagement* am DFD. Meinen Lektoren Tobias Ullmann, Carina Kübert, Gunther Schorcht und nicht zuletzt Frau Gerriet Harms danke ich für die investierte Zeit beim Lesen der Skripte und die hilfreichen Anregungen.

Ein großer Dank geht auch an das TerraSAR-X Science Team am DFD für die stets unkomplizierte Datenlieferung und gute Unterstützung bei allen Fragen bezüglich der Daten. Meinen tapferen Radarmitstreitern Martin Schmidt und Andreas Schenk danke ich für die sehr gute und ideenreiche Zusammenarbeit. Frau Linda Firmbach danke ich ganz herzlich nicht nur für die gute Unterstützung bei der graphischen Gestaltung, sondern auch ganz besonders dafür, mir eine große motivative und emotionale Stütze gewesen zu sein.

Nicht zuletzt möchte ich meiner Familie für das Vorleben bedingungsloser Zuverläs-

sigkeit und Unterstützung danken. Ihre vorgelebte Ruhe, Geduld und Bescheidenheit sind in Maßen ein wichtiges Gut, nicht zuletzt in Wissenschaft und Forschung.

Inhaltsverzeichnis

Abbildungverzeichnis	XI
Tabellenverzeichnis	XIII
1 Einleitung	1
1.1 Zielstellung dieser Arbeit	3
1.2 Radarfernerkundung im urbanen Raum	6
2 Methodische Grundlagen	13
2.1 Grundlagen der Radarfernerkundung	13
2.1.1 Das Messprinzip	13
2.1.2 Radar mit realer Apertur	16
2.1.3 Radar mit synthetischer Apertur	23
2.2 Grundlagen der Bildverarbeitung	28
2.2.1 Klassifikationsverfahren	28
2.2.2 Objektorientierte Bildverarbeitung	30
2.2.3 Veränderungsanalysen	35
2.2.4 Texturmaße als Eingangsparameter zur Klassifikation	37
3 Untersuchungsgebiet und Datengrundlage	47
3.1 Untersuchungsgebiet	47
3.2 Radarmissionen	55
3.2.1 TerraSAR-X	55
3.2.2 ALOS-PALSAR	58
3.3 Datenbeschreibung	59
4 Klassifikation von Siedlungsräumen in SAR Daten	63
4.1 Erfassung bebauter Areale in TSX <i>Stripmap</i> -Daten	64
4.1.1 Objektorientierter Ansatz	64
4.1.2 Pixelbasierter Ansatz	73
4.2 Übertragung auf SC- und SL-Modi sowie PALSAR	77
4.2.1 TerraSAR-X <i>ScanSAR</i>	78
4.2.2 TerraSAR-X <i>Spotlight</i>	79

4.2.3	ALOS-PALSAR	80
4.3	Erfassung einfacher Landbedeckungstypen	81
4.4	Analyse von Baugebieten	88
4.5	Validierung der Ergebnisse	93
5	Ergebnisse und Diskussion	97
5.1	Erfassung bebauter Areale mit Hilfe von SAR-Daten	97
5.1.1	Objektorientierter Ansatz	98
5.1.2	Pixelbasierter Ansatz	104
5.1.3	Vergleich der beiden Verfahren	107
5.2	Übertragung der Methodik	110
5.2.1	Räumliche Übertragung	111
5.2.2	Übertragung in der Zeit	112
5.2.3	TerraSAR-X <i>Spotlight</i>	117
5.2.4	TerraSAR-X <i>ScanSAR</i>	120
5.2.5	ALOS-PALSAR	121
5.3	Erfassung einfacher Landbedeckungstypen	123
5.4	Analyse von Baugebieten	129
6	Fazit und Ausblick	137
6.1	Klassifikation von Siedlungsräumen in SAR-Daten	137
6.2	Ausblick	140
A	Anhang Daten	145
B	Anhang Methoden	147
C	Anhang Ergebnisse	151
	Abkürzungsverzeichnis	165
	Literaturverzeichnis	167
	Eidesstattliche Erklärung	181
	Lebenslauf	183

Abbildungsverzeichnis

Kapitel 2

2.1	Einteilung des Spektrums elektromagnetischer Strahlung	14
2.2	Aufnahmegeometrie eines Radarsystems	18
2.3	Die Auflösungszelle in Radarsystemen	20
2.4	Geometrische Effekte in Radaraufnahmen	21
2.5	Streuverhalten verschiedener Oberflächen	23
2.6	Aufnahmemodi eines SAR-Systems	26
2.7	Zusammensetzung des Gesamtsignals	27
2.8	<i>Speckle</i> in homogen strukturierten Arealen	28
2.9	SAR-Objekt im urbanen Kontext	35
2.10	Ermittlung des Bildrauschens	40
2.11	<i>Flowchart</i> zur Ermittlung der Texturlayer	42
2.12	Ermittlung der Grauwert-Kookkurrenzmatrizen	43
2.13	Vergleich von C_w - und GLCM-Texturen	45

Kapitel 3

3.1	Weltweite Verteilung der Untersuchungsgebiete	49
3.2	Untersuchungsareale im Stadtgebiet von München	54

Kapitel 4

4.1	Objektorientierte Klassifikation bebauten Areals	67
4.2	Grobe Segmentierung L1	68
4.3	Klassifikationsschritte der objektorientierten Methodik	70
4.4	Schema der pixelbasierten Erfassung von 'bebautem Areal'	75
4.5	Ablauf der pixelbasierten Erfassung von bebautem Areal	76
4.6	Pixelbasierte Landnutzungsklassifikation	82
4.7	Intensitäts-Histogramme der Landbedeckungsklassen	84
4.8	\bar{C}_T^2 -Histogramm der Landbedeckungsklassen	85
4.9	Ermittlung der Schwellwerte	87
4.10	Baustelle Bernhard-Wicki-Straße	89
4.11	Streuverhalten am Beispiel einer Baustelle	90
4.12	Methodik zur Klassifikation von Baustellen	93

Kapitel 5

5.1	Ergebnisse der objektorientierten Erfassung bebauter Areale	101
5.2	Diskussion der objektorientierten Erfassung bebauter Areale	105
5.3	Beispiel einer lückenhaften Erfassung von bebautem Areal	106
5.4	Vergleich der beiden Verfahren zur Erfassung bebauter Areale	108
5.5	Beispiel der zeitlichen Übertragung der Siedlungserfassung	117
5.6	Ergebnis der Klassifikation der Landbedeckung	126
5.7	Variation der erfassten Veränderungsflächen	130
5.8	Bewertung der Merkmalsrelevanz	132
5.9	Ergebnisbeispiele für die Erfassung von Baustellen	134

Anhang B

B.1	Histogramme der Intensität der Trainingsgebiete	148
B.2	Histogramme der Textur der Trainingsgebiete	149
B.3	Weitere geometrische Effekte in Radaraufnahmen	150

Anhang C

C.1	Weitere Ergebnisse der objektorientierten Erfassung bebauter Areale .	154
C.2	Ergebnisse der pixelbasierten Erfassung bebauter Areale	156
C.3	Ergebnisse der Übertragung auf TSX-SL-HR Daten	158
C.4	Histogramme der Intensität der vier Untersuchungsräume	159
C.5	Histogramme der Textur der vier Untersuchungsräume	160
C.6	Ergebnisse der Landbedeckungsklassifikation	163

Tabellenverzeichnis

Kapitel 2

2.1	Bandbreiten der Radarbänder	15
-----	---------------------------------------	----

Kapitel 3

3.1	Untersuchungsgebiete	51
3.2	Untersuchte Baustellen	53
3.3	Zusammenfassung der TerraSAR-X Spezifikationen	56
3.4	TerraSAR-X Aufnahmemodi-Spezifikationen	57

Kapitel 4

4.1	Abkürzungen der Klassen und Schwellwerte objekt-orientiert	65
4.2	Parametereinstellung für die <i>Multiresolution</i> -Segmentierung	66
4.3	Schwellwerte zur objektorientierten Erfassung von bebautem Areal	71
4.4	Abkürzungen der Klassen und Schwellwerte pixel-basiert	74
4.5	Schwellwerte zur pixelbasierten Erfassung von bebautem Areal	75
4.6	Schwellwerteinstellung im SC-Modus	79
4.7	Schwellwerteinstellung im SL-Modus	80
4.8	Schwellwerteinstellung für PALSAR Daten	81
4.9	Einteilung der Testgebiete in zwei Kategorien	83

Kapitel 5

5.1	Genauigkeiten der objektorientierten Erfassung bebauter Areale	99
5.2	Genauigkeiten auf Basis individueller Parametersätze	102
5.3	Genauigkeiten der pixelbasierten Erfassung bebauter Areale	107
5.4	Weitere Ergebnisse der pixelbasierten Erfassung bebauter Areale	111
5.5	Ergebnisse der Tests zur zeitlichen Übertragung	113
5.6	Größe der Untersuchungsgebiete und Veränderungen	114
5.7	Flächenanteile mit realer Veränderung	115
5.8	Häufigkeit von Fehlinterpretationen	116
5.9	Genauigkeiten auf Basis von TSX <i>Spotlight</i> Daten	119
5.10	Genauigkeiten auf Basis TSX <i>ScanSAR</i> Daten	120
5.11	Vergleich der Ergebnisse von TerraSAR-X und ALOS-PALSAR	122
5.12	Schwellwerte für die Landbedeckungsklassifikation	124

5.13	Gesamtergebnisse der Landbedeckungsklassifikation	125
5.14	Aufnahmetermine der TSX-SL-HR Daten	129
5.15	Anteile von Veränderungsflächen auf den Baugebieten	131
5.16	Genauigkeiten bei der Erfassung von Baustellen	133

Anhang A

A.1	Aufnahmeparameter der verwendeten SAR-Szenen	145
-----	--	-----

Anhang C

C.1	Hersteller- und Nutzergenauigkeiten der Landbedeckungsklassifikation	161
-----	--	-----

1

Einleitung

Siedlungsräume sind die Zentren menschlicher Entwicklung. Entwicklung bedeutet für den jeweiligen Siedlungsraum immer auch Veränderung. Die Ursachen dieser Veränderung können vielseitig sein: Zunahme oder Schrumpfung der Bevölkerung, Anpassungen an neue Mobilitätsgewohnheiten, Modifizierungen der Bausubstanz und viele mehr. Gerade die weltweite Bevölkerungsentwicklung in den letzten Dekaden, die Verdopplung der Bevölkerung seit etwa 1970 bei gleichzeitiger Erhöhung des städtischen Anteils an der Bevölkerung von 37% auf 52% (Vereinte Nationen 2011b), ist derzeit ein wichtiger Treiber für Veränderungen im Siedlungsraum. Je nach Art und Ursache ziehen diese Veränderungen vielfältige Folgen nach sich, die direkt oder indirekt Auswirkungen auf die Lebensverhältnisse der betroffenen Einwohner haben können. Entsprechend ist eine im Vorfeld stattfindende Abschätzung der Folgen dieser Dynamik von Interesse für die Bevölkerung und somit auch der Planer. Ist eine solche Abschätzung nicht möglich, sollte zumindest eine frühzeitige Erkennung statt finden. Dieser Früherkennung sind auf Basis traditioneller Methoden enge Grenzen gesetzt, die vorwiegend durch die zu veranschlagenden Kosten, Zeit und Personal bestimmt werden. In jüngerer Zeit erlangen daher vermehrt fernerkundliche Verfahren Einzug in die Bestimmung und Bewertung des aktuellen Zustandes von Siedlungsräumen (Miller und Small 2003, Taubenböck und Dech 2010). Diese Entwicklung ist insbesondere mit der Verbesserung der geometrischen Auflösung verbunden, wodurch die kleingliedrigen Strukturen des Siedlungsraumes erst erfasst werden können. Zunächst betraf dies ausschließlich optische Systeme, deren geometrische Auflösung sukzessive

auf unter einem Meter verbessert wurde. In den letzten Jahren nimmt auch die Anzahl satellitengetragener aktiver Systeme, deren Auflösungsvermögen ebenfalls die Meter-Grenze unterschreiten, zu. Hier seien insbesondere die Radar-Systeme TerraSAR-X und COSMO-SkyMed zu nennen, beide sind mit Radar mit synthetischer Apertur (SAR) ausgestattet. Da SAR-Systeme zudem den Vorteil bieten, weitestgehend unabhängig von Witterungsbedingungen und Tageszeit Daten liefern zu können, stellen sie eine interessante Alternative zur Bestimmung des Status Quo urbaner Räume dar (Esch 2006).

Die deutsche TerraSAR-X/TanDEM-X Mission begann im Juni 2007 mit dem Start des ersten von zwei Zwillingssatelliten TerraSAR-X (TSX), diesem folgte im Jahr 2010 TanDEM-X (TDX) (Moreira und Bamler 2010). TerraSAR-X stellte etwa zeitgleich mit dem italienischen System COSMO-SkyMed (ASI 2007, 2012) erstmalig sehr hoch aufgelöste Bilddaten im X-Band aus dem All bereit. Das Ziel der TanDEM-X Mission ist die Erstellung eines weltweiten Höhenmodells mit einer horizontalen Rasterauflösung von 12m und einer absoluten vertikalen Genauigkeit von 10m (Hueso González et al. 2010, DLR 2011). Von den beiden baugleichen Satelliten werden weltweit Daten als Stereopaare aufgenommen. Jeweils ein Sensor sendet Strahlung aus, beide Sensoren empfangen. Demnach fungiert das Satellitenpaar als erstes konfigurierbares SAR-Interferometer im All (DLR 2011). Als Nebenprodukt zum Höhenmodell bilden die beiden Sensoren die komplette Landoberfläche in einem Zeitraum von etwa fünf Jahren hochaufgelöst ab.

Aufbauend auf Erfahrungen, die in den 1980er Jahren mit dem X-SAR Instrument an Bord des *Space Shuttle* gemacht wurden, legt die Konzeption von TSX einen starken Fokus auf die Beobachtung der Landoberfläche. Werninghaus und Buckreuss (2010) nennen, neben der Entwicklung von Methoden zur SAR Verarbeitung, die übergeordneten Forschungskomplexe 'Landbedeckung', 'Vegetation und Sicherheit' und 'Risikomanagement' als die Schwerpunkte der missionsbegleitenden Forschungsarbeiten.

Die Entwicklung von TerraSAR-X ist die erste deutsche Satellitenmission, die in einer öffentlich-privaten Partnerschaft umgesetzt wurde. Für den öffentlichen Teil vertritt das Deutsches Zentrum für Luft- und Raumfahrt (DLR) die Bundesrepublik

Deutschland. Ihr obliegen das Management der Missionen sowie die Koordination der wissenschaftlichen Arbeiten mit diesen Daten. Der private Partner ist die Infoterra GmbH (ITD), ein Tochterunternehmen von EADS Astrium. Der Fokus von ITD liegt, neben eigenen Forschungsansätzen, auf der Entwicklung und Generierung von kommerziellen Verwertungsmöglichkeiten der Daten (Werninghaus und Buckreuss 2010). Ihr Fernziel ist die rein privatwirtschaftliche Finanzierung des TSX Nachfolgers TerraSAR-X-2.

Die Beteiligung der Privatwirtschaft an der TerraSAR-X/Tandem-X Mission begründet ein verstärktes Interesse der Datenverwendung auf Produkte, die wirtschaftlich in Wert gesetzt werden können. Am Lehrstuhl für Fernerkundung der Universität Würzburg wurden aus diesem Grunde, im Zuge eines vom Deutschen Zentrum für Luft- und Raumfahrt mit Mitteln des Bundesministerium für Wirtschaft und Technologie (BMWi) unter dem Kennzeichen 50EE0619 geförderten Projektes, Methoden zur automatisierten und robusten Erfassung von Siedlungsräumen aus TSX-Daten entwickelt. Dieses Projekt ist eines von insgesamt 22 geförderten Forschungsvorhaben im Kontext des TerraSAR-X Starts, die den urbanen Raum als Fokusgebiet haben. Die hier vorgestellten Entwicklungen stehen in enger Beziehung zu diesem Projekt.

Mit dem Start der neuen Generation von SAR-Sensoren werden erstmalig flächendeckend höchstauflöste SAR-Daten zur Verfügung stehen. Diese Auflösung ermöglicht eine detaillierte Abbildung urbaner Räume. In Verbindung mit der weitestgehenden Unabhängigkeit von Wetter und Tageszeiten stellt TerraSAR-X ein mächtiges Instrument zur Informationsbeschaffung und Charakterisierung von Städten dar. Aus diesem Grund werden in dieser Arbeit zunächst Methoden zur großräumigen Erfassung und Bewertung urbaner Räume entwickelt. Im Anschluss daran werden erste Analysen zu einer feineren Charakterisierung des Siedlungsraums vorgenommen.

1.1 Zielstellung dieser Arbeit

Das übergeordnete Ziel der hier vorliegenden Arbeit ist zu testen, mit welcher Qualität Methoden zur Beschreibung von Siedlungsräumen auf Basis von SAR-Daten erstellt werden können, und inwiefern diese Methoden

übertragbar sind.

Methodisch setzen die hier vorgestellten Arbeiten in Teilen auf früheren Forschungsarbeiten von Esch (2006), die im Kontext erster TSX-Nutzungsvorbereitungen erstellt wurden, auf. Sie fokussieren jedoch auf der Nutzung von Texturinformationen, welche Heterogenitäten in der Grauwertverteilungen innerhalb einer SAR-Aufnahme beschreiben.

Im Detail werden folgende Schwerpunkte bearbeitet:

- Die Entwicklung einer Methode zur automatisierten Erfassung von bebauten Arealen aus hochaufgelösten TerraSAR-X Daten. Um die Eignung dieser Methode im Sinne der Übertragbarkeit zu überprüfen, wird diese in vier Varianten getestet: räumlich, zeitlich, auf unterschiedlichen Datenprodukten und auf Datensätzen eines anderen Radarsensors. Diese Entwicklungen stellen eine Weiterentwicklung der Arbeiten von Esch (2006) dar und zielen auf eine Beschleunigung und eine weitgehende Automatisierung der Verarbeitung.
- Im Anschluss wird das entwickelte Klassifikationsschema erweitert, um die Landbedeckung im Umfeld von Siedlungsflächen zu bestimmen. Dabei werden, in Anlehnung an Bruzzone et al. (2004), die vier Basisklassen 'Wasser', 'Wald', 'Urbaner Raum' sowie 'Offenland' unterschieden. Der Grundgedanke dieser Basisklassen ist die Bereitstellung einer Vorklassifikation.
- Eine detaillierte Betrachtung der Siedlungsräume, bei der exemplarisch Baugebiete auf ihre Abbildung und Erfassbarkeit hin untersucht werden. Baugebiete sind von besonderem Interesse im Kontext urbaner Räume, da sie deren hohe Entwicklungsdynamik widerspiegeln und, aus Sicht der Fernerkundung, den Startpunkt der Oberflächentransformation darstellen.

Mit den ersten beiden Schwerpunkte wird vorrangig die Beschreibung von Siedlungsräumen und deren Umfeld vorangetrieben: Zunächst die spezialisierte Anwendung zur Abgrenzung bebauter Flächen und dann die Beschreibung des Umfeldes dieser Areale. Beide Anwendung können somit dem Anwender (z. B. dem Planer) die zum Aufnahmezeitpunkt aktuelle Ausprägung eines Siedlungsraums zeigen. Liegen

Daten von verschiedenen Terminen vor, kann, bei gegebener Eignung, eine Beschreibung der Veränderung zwischen den Aufnahmetermenen ermöglicht werden. Die Eignung zur Beschreibung von Veränderungen wird im Zuge der Erfassung bebauter Areale untersucht und beschrieben.

Baugebiete bedeuten immer eine Veränderung des *status quo*, somit zielt der dritte Schwerpunkt verstärkt auf die Bereitstellung von Informationen über potentielle strukturelle Veränderungen. Es können Fokusregionen identifiziert werden, auf die nähere Untersuchungen bezüglich anstehender Veränderungen konzentriert werden, ob über Feldbegehungen oder über die Auswertung neuerer Satellitendaten. An dieser Stelle sei beispielsweise auf das etablierte Konzept der Erfassung von Urbanen Strukturtypen (UST) aus Fernerkundungsdaten hingewiesen (vgl. dazu Wurm und Taubenböck (2010), Banzhaf und Höfer (2008), Pauleit und Duhme (2000)).

Aufbau der Arbeit Die vorliegende Dissertationsschrift beginnt mit einem Überblick über den Stand der Forschung im Bereich SAR-Klassifikation, insbesondere der Urbanen Radarfernerkundung, um die Grundlagen dieser Arbeit darzulegen. Im weiteren Verlauf der Arbeit werden Texturmaße und die objektorientierte Bildverarbeitung eine herausragende Stellung einnehmen. In diese Themen wird in Kapitel 2 eingeführt. Im 3. Kapitel wird mit einer Einführung in das Untersuchungsgebiet 'Urbaner Raum', den Grundlagen der Radarfernerkundung und einer Beschreibung der Datengrundlage die Basis zum Verständnis der vorzustellenden Methoden gegeben. Da die hier vorgestellte Arbeit die Nutzung von TSX-Daten verfolgt, wird bei der Beschreibung der Datengrundlage ein verstärkter Fokus auf die TSX-Mission gelegt. In der nachfolgenden Methodenvorstellung liegt der Schwerpunkt auf der Erfassung von bebauten Arealen. Dabei wird zunächst eine objektorientierte Methodik entwickelt. Die dabei gewonnenen Erkenntnisse werden im Anschluss aufgrund der besseren Umsetzung in operationelle Ketten auf ein pixelbasiertes Verfahren übertragen und dort umfassend getestet. Die oben bereits erwähnten weiteren Methoden zur Landbedeckungsklassifikation und der Erfassung von Baustellen werden im Anschluss beschrieben. Kapitel 5 liefert die erzielten Ergebnisse und bewertet diese. Zum Abschluss wird, basierend auf den zuvor dargelegten Arbeiten, ein kritischer Überblick über die Möglichkeiten und Perspektiven der Radarfernerkundung im urbanen Kontext gegeben.

1.2 Radarfernerkundung im urbanen Raum

In diesem Kapitel wird ein Überblick über den Stand der Forschung der Fernerkundung Urbaner Räume und im Speziellen der Radarfernerkundung gegeben. Der Fokus liegt, da bei der Klassifikation von SAR-Daten Texturmaße traditionell eine wichtige Rolle spielen, auf der Besprechung aktueller Forschungsarbeiten zu ihrer Inwertsetzung.

Im urbanen Raum Die Fernerkundung Urbaner Räume hat in den letzten Jahren stark an Bedeutung gewonnen (Ehlers 2007). Dies wird nicht allein durch die wachsende Zahl entsprechender Fachliteratur wie Donnay et al. (2001), Netzband et al. (2007), Weng und Quattrochi (2007), Weng (2008), Soergel (2010), Rashed und Jürgens (2010) sowie Taubenböck und Dech (2010) belegt. Auch die internationalen Fachjournale widmeten diesem Thema viel Raum. Das *Institute of Electrical and Electronics Engineers (IEEE)* beispielsweise legte in ihrem 'Journal of Selected Topics in Applied Earth Observations & Remote Sensing' Anfang 2008 eine Spezialausgabe zum Thema Fernerkundung von Siedlungsräumen auf, um den Stand der Forschung und künftige Herausforderungen zu umreißen. Das *Open Access Journal 'Remote Sensing'* widmete dem Themenkomplex der Urbanen Fernerkundung eine Spezialausgabe.

Dass die Urbanen Räume in den Fokus der fernerkundlichen geographischen Analysen geraten sind, hängt mit der Entwicklung der fernerkundlichen Sensorik zusammen. Erst die verbesserte geometrische Auflösung moderner Aufnahmesysteme ermöglicht es, die Kleingliedrigkeit und hohe Heterogenität innerhalb städtischer Agglomerationen in ansprechender Weise abzubilden (Gamba et al. 2008). Gepaart mit den Vorzügen der Satellitenfernerkundung - große räumliche Abdeckung und relativ hohe Repetitionsrate - kann die fernerkundliche Analyse urban geprägter Räume Informationen zu wichtigen Fragestellungen sowohl der geographischen als auch der Ökosystemforschung leisten (Hostert 2007).

Zur Beantwortung urbaner Fragestellungen wird verstärkt auf die Daten optischer Aufnahmesysteme zurückgegriffen, insbesondere die Auswertung von Luftbildern hat

eine lange Tradition (Hostert 2007). Verschiedene Entwicklungen aktueller, überwiegend auf optischen Datensätzen basierender Arbeiten werden unter anderem in Donay et al. (2001), Netzband et al. (2007) und Weng und Quattrochi (2007) dargestellt. Diese Editorensammlungen enthalten eine Reihe unterschiedlicher Forschungsarbeiten, wie zum Beispiel Techniken zur Klassifizierung urbaner Räume bzw. zur Abschätzung der urbanen Bevölkerung. Dabei stellen Weng und Quattrochi (2007) konkrete Forschungsergebnisse vor, Netzband et al. (2007) hingegen konzentriert sich auf konzeptionelle Fragen bei der Untersuchung urbaner Teilaspekte. Weng (2008) fokussiert auf die Erfassung und Bewertung von versiegelten Flächen, Ehlers (2007) und Hostert (2007) geben jeweils einen Überblick über mögliche zukünftige Entwicklungen der Fernerkundung Urbaner Räume. Eine auf Planungsfragen und -aspekte zielende Übersicht aktueller Forschungsarbeiten des deutschsprachigen Raums leisten Taubenböck und Dech (2010). In diesem letztgenannten Kontext sind auch die hier vorliegenden Arbeiten zu sehen. Eine kurze Einführung in die Thematik der urbanen Fernerkundung liefern Gamba et al. (2008), wobei unter anderem auch die Radarfernerkundung angesprochen wird.

Radarfernerkundung SAR Intensitätsszenen sind in der Regel einkanalige Bildprodukte, es sei denn, es werden verschiedene Polarisationen oder unterschiedliche Aufnahmetermine miteinander verbunden. Der Informationsgehalt dieser Bilddaten ist im Vergleich mit multispektralen optischen Daten geringer, und Klassifikationsverfahren auf Basis der Intensitätswerte können nur unzureichend umgesetzt werden (Herold et al. 2005). Daher werden weitere Informationsebenen generiert, um die reine Intensitätsinformation zu ergänzen. Diese zusätzlichen Informationsebenen können Statistiken verschiedener Ordnungsstufen, Informationen auf Segmentebene oder Texturmaße sein. Ndi Nyoungui et al. (2002) unterscheiden auf drei Testgebieten in Kamerun und Kanada die jeweils wichtigsten Landbedeckungstypen mit einer Genauigkeit von bis zu 94% anhand einer überwachten Klassifikation mit künstlichen neuronalen Netzen. Dabei zeigt sich, dass Statistiken zweiter und dritter Ordnung bessere Ergebnisse liefern als solche erster Ordnung. Basierend auf ERS-1 Daten testen Rajesh et al. (2001) verschiedene Texturmaße (u. a. *run length features*, *texture spectrum* und Kookkurrenzmatrizen) auf ihr Potential zur Trennung von vier SAR-Basisklassen anhand eines ISODATA-Algorithmus. Eine explizite Betrachtung von

Texturmaßen auf Basis von Kookkurrenzmatrizen nach Haralick et al. (1973) auf Radarsat-1 Intensitäten wurde von Hu et al. (2008) vorgenommen. Diese wurden dabei auf ihre Eignung zur Trennung von fünf Basisklassen hin untersucht. Im Ergebnis konnte eine zufriedenstellende Gesamtgenauigkeit von etwa 76% im besten Fall bei einem Kappa von 0,63 erzielt werden. Deutlich wird auch hier der Gewinn der Klassifikationsgenauigkeit durch Hinzunahme von Texturmaßen herausgestellt.

Radarsysteme, speziell solche mit synthetischer Apertur, arbeiten weitestgehend unabhängig von Wetter und Tageszeit und zeichnen sich daher in der Analyse urban geprägter Räume durch eine hohe Datenverfügbarkeit aus. Von besonderer Bedeutung ist zudem, dass das empfangene Signal in direkter Abhängigkeit zu den geometrischen Eigenschaften (vgl. Abschnitt 2.1) des untersuchten Raumes steht (Reigber und Moreira 2000, Fornaro et al. 2005). Ein Überblick über einige ältere Studien im Kontext der Beobachtung urbaner Räume geben Henderson und Xia (1997, 1998), darunter solche, die sich der Abschätzung des menschlichen Einflusses auf die Umwelt, der Bevölkerungsabschätzung, der Änderungsanalyse der Landnutzung in urban geprägten Regionen sowie der Abgrenzung bebauter Areale in SAR-Daten widmen. Im Folgenden wird eine Übersicht zu jüngeren Studien im Kontext der Urbanen Radarfernerkundung gegeben.

Frate et al. (2008) finden für die Stadt und das Umland von Rom für insgesamt sieben Klassen eine Gesamtgenauigkeit zwischen 86,5% bis zu 92,0% für drei Jahreschnitte in der Zeit von 1994 bis 1999. Ihre Arbeit basiert auf Daten der *European Remote Sensing Satellite* (ERS)-1/2 Missionen und nutzt neben multitemporalen Datensätzen und den daraus abgeleiteten Kohärenzen auch Kookkurrenzmatrizen nach Haralick et al. (1973). Ebenfalls basierend auf Daten des ERS-Tandems entwickeln Bruzzone et al. (2004) anhand von Langzeit-Kohärenzen und zeitlichen Variabilitäten unter Anwendung von künstlichen neuronalen Netzen ein Klassifikationsschema zur Trennung der vier Klassen 'Wald', 'Urbanes Areal', 'Wasser' und 'Felder'. Dabei erreichen die Autoren eine Klassifikationsgüte von 92,2%. Diese Klasseneinteilung wird im späteren Verlauf der hier vorgestellten Arbeiten aufgegriffen. Herold et al. (2005) finden auf drei Testgebieten in Ostafrika und im Himalaya anhand variierender Klassen und Merkmale, dass die Intensitätsdaten des kanadischen Radarsat und die *Shuttle Interferometric Radar* (SIR)-B Daten für sich alleine nicht hinreichend zur Landbede-

ckungsklassifikation geeignet sind. Es gelingt jedoch, über die Nutzung verschiedener aus den Intensitätsdaten abgeleiteter Informationen, das Ergebnis um 20-30% zu verbessern. Ein wichtiges Ergebnis dabei ist, dass, in Abhängigkeit vom Testgebiet und der Klasse, verschiedene Ableitungen aus den Intensitätsdaten die beste Eignung zur Klassifikation aufzeigen (eine genauere Herleitung wird nicht vorgenommen).

Auf Basis vollpolarimetrischer *Airborne* SAR (AIRSAR) C- und L-Band Daten entwickelt Pellizzeri (2003) einen objektorientierten Ansatz zur Einteilung von insgesamt fünf Klassen. Nascimento et al. (2010) besprechen die verschiedenen Grauwert-Verteilungsformen der Landbedeckungstypen 'Urban', 'Wald' und 'Grasland' anhand einer Anpassung an die theoretische G_0 -Verteilung mit dem Ziel, die Merkmalsauswahl für SAR-Klassifikationen zu erleichtern. Bei einem Vergleich von reiner SAR-Klassifikation mit der kombinierten Nutzung von SAR- und optischen Daten erhalten Riedel et al. (2006) mit der kombinierten Nutzung ein deutlich besseres Ergebnis. Wird jedoch eine SAR-Zeitreihe statt eines einzelnen Aufnahmetermins verwendet, nivelliert sich das Ergebnis im Vergleich zur SAR-Optik-Fusion nahezu. Ein Klassifikationsschema basierend auf dem Abgleich mit der theoretischen G_A^0 -Verteilung zeigt sehr gute Ergebnisse für unterschiedliche Landbedeckungsklassen (Mejail et al. 2003). Die Klassifikation wird dabei anhand eines überwachten Gaußschen-*maximum-likelihood* Verfahrens auf Ausschnitten einzelner *Experimental Airborne SAR* (E-SAR) und *Japanese Earth Resources Satellite* (JERS-1) Daten durchgeführt. Lisini et al. (2008), Dell'Acqua et al. (2009) sowie Dell'Acqua und Gamba (2010) verknüpfen verschiedene Methoden (u.a. von He et al. (2006) und Pesaresi et al. (2007)) zu einem *rapid mapping*-Klassifikationsschema. Die verwendeten Methoden werden durch neue Entwicklungen erweitert und grenzen im Hinblick auf eine Basisklassifikation die Klassen 'Wasser', 'Vegetation', 'Siedlungsraum' und 'Straßen' mit guten Ergebnissen voneinander ab. Weiteres Potential dieser Methode zeigt sich in der exakteren Abgrenzung von Siedlungsräumen gegenüber Wäldern.

Die aufgeführten Studien verdeutlichen, dass die Klassifikation urbaner Räume auf Basis von SAR-Daten allein über monotemporale Intensitätsdaten zu unbefriedigenden Ergebnissen führt. Während sich Riedel et al. (2006) auf eine Kombination von SAR und optischen Aufnahmen stützen, erhalten Frate et al. (2008) und Bruzzone et al. (2004) über die Verwendung verschiedener Zeitschnitte gute Ergebnisse.

Herold et al. (2005) verwenden eine Kombination monotemporaler Intensitätsdaten mit daraus abgeleiteter Informationen. Die hier vorliegende Arbeit orientiert sich an den Herangehensweisen von Rajesh et al. (2001), Hu et al. (2008) sowie Herold et al. (2005), indem zur Ableitung der Landbedeckung aus TSX-Daten die Intensitätsinformation eines monotemporalen, einfachpolarisierten Datensatzes sowie daraus abgeleitete Texturmaße herangezogen werden.

Weitere Studien beschäftigen sich mit der Analyse der Rückstreuungseigenschaften der Mikrowellenstrahlung in bebauten Arealen. Xia und Henderson (1997) fassen verschiedene Studien zu den Beziehungen bio- und geophysikalischer Parameter mit dem Radarrückstreusignal in urbanen Räumen zusammen. Tupin und Roux (2003) extrahieren Gebäudeumrisse anhand einer Fusion von SAR- und optischen Daten. Das gleiche Ziel verfolgen die Studien von Stilla et al. (2003) sowie Michaelsen et al. (2005). Dabei beruhen die Arbeiten bei Stilla et al. (2003) auf interferometrisches SAR (InSAR)-Daten des luftgestützten AER-II-Sensors und zeigen, dass die Abgrenzung von Gebäudeumrissen in InSAR-Daten zwar möglich, ihre Darstellung aus *Light Detection and Ranging* (LIDAR)-Daten jedoch zu bevorzugen ist. Die Daten des neueren luftgestützten Sensors PAMIR hingegen zeichnen sich gegenüber den AER-II-Daten durch eine verbesserte Abbildung der Gebäudeumrisse aus (Michaelsen et al. 2005). Ebenfalls auf Basis von 20cm PAMIR-Daten zeigen Soergel et al. (2005) das Potential höchstauflösender SAR-Daten in der Analyse urbaner Räume. Dabei wird herausgestellt, dass die PAMIR-Daten gegenüber Höhenmodellen eine detailliertere Abbildung des Raumes und insbesondere der Gebäudestrukturen leisten. In einer Analyse von ERS-1/2-Kohärenzen für urbane Merkmale und bepflanzte Flächen konnte Weydahl (2001) zeigen, dass Gebäudestrukturen auch über längere Zeiträume hohe Kohärenzen aufzeigen und somit gut als Referenzziele für weitere Arbeiten dienen können. Auf Basis von Daten des luftgestützten E-SAR Sensors des Deutschen Zentrums für Luft- und Raumfahrt (DLR) diskutieren Guida et al. (2008) sowohl die geometrischen als auch die elektromagnetischen Eigenschaften von Gebäuden und deren Abbildung in einem Datensatz. Ebenfalls auf den Daten des E-SAR Sensors, und zusätzlich auf den L-Band AIRSAR-Daten, bauen die Untersuchungen von Ainsworth et al. (2008) auf, deren Ziel die Charakterisierung von Strukturen des bebauten Areals ist. Dabei finden vollpolarimetrische Daten Anwendung, außerdem wird die gute Abgrenzung von urbanen Räumen gegenüber den umliegenden Flächen herausgestellt. Für das

Gebiet der Stadt Shanghai (China) finden Liao et al. (2005) eine gute Anwendbarkeit für ERS-1/2-Kohärenz-Daten für Veränderungsanalysen. Eine Änderungsanalyse mit ERS-Langzeit-Kohärenzdaten für das Stadtgebiet von Cardiff (Wales) zeigt, dass die Möglichkeit zur Erfassung von Veränderungen von der Art der Flächen die eine Veränderungen aufweisen abhängt (Grey et al. 2003). Dieser Gedanke von Grey et al. (2003) wird in Abschnitt 4.4 aufgegriffen. Dabei werden erste Untersuchungen vorgestellt, die zeigen, inwiefern aus gegebenen Veränderungsflächen über die Nutzung von Texturmaßen auf die Art der Flächen geschlossen werden kann. Als Zielareale werden dabei Baugebiete gewählt. Diese stellen wichtige Indikatoren für die Entwicklungsdynamik einer Stadt dar und markieren zudem Bereiche, in denen mit Veränderungen des bestehenden städtischen Systems zu rechnen ist.

Die Abgrenzung von Siedlungsflächen gegenüber ihrem Umland basierend auf SAR-Daten hat eine lange Tradition (Henderson und Xia 1997, 1998). Der Grund hierfür ist in der ausgeprägt guten Unterscheidbarkeit von bebauten Arealen gegenüber naturnahen Flächen wie Wäldern und Ackerflächen (Ainsworth et al. 2008) zu sehen. He et al. (2006) verwenden ein adaptives iteratives Verfahren zur Abgrenzung von urbanen Räumen aus einfach-polarisierten SAR-Daten, das auf dem FFmax Algorithmus von Gouinaud und Tupin (1996) basiert. In vier Arbeitsschritten, von grober Abgrenzung bis hin zum *iterated maximum selecting*-Verfahren zur Verfeinerung, wird eine grobe Abgrenzung des urbanen Raumes erreicht, die als Vorklassifikation für weitere Analysen dienen kann. Die einzelnen Verfeinerungsschritte sind dabei insbesondere zur Unterscheidung der Bergkämme von Siedlungsräumen notwendig. Ein objekt-orientiertes Verfahren, welches unter anderem die Objektgröße als Klassifikationskriterium verwendet, wird von Esch (2006) vorgestellt. Dabei werden auf zwei ERS-Szenen der Region Mannheim/Ludwigshafen sehr gute Ergebnisse erzielt. Stasolla und Gamba (2008a,b) nutzen lokale Indikatoren mit räumlicher Zuordnung (engl. *local indicators of spatial association*, LISA) in einer semi-automatischen Methode zur Erfassung von Siedlungsräumen. Auf einzel-polarisierten Datensätzen des kanadischen Radarsat-1 und des japanischen *Advanced Land Observation Satellite* (ALOS) (Stasolla und Gamba 2008b) sowie des TSX (Stasolla und Gamba 2008a) werden auf insgesamt vier Testgebieten Gesamtgenauigkeiten von über 90% erzielt. Die Ergebnisse hingegen, die Corbane et al. (2008) allein auf Basis von Texturanalysen der Radarsat-1- oder ENVISAT-Daten erzielen, enttäuschen. Weder in dem flachen Ter-

rain von Bukarest (Rumänien) noch in der Gebirgslandschaft von Cayenne (Frankreich) konnte die Erfassung des Siedlungsraums aus monotemporalen SAR-Daten zufriedenstellend umgesetzt werden. Dabei wird auf beiden Testgebieten eine ausgeprägte Unterklassifizierung festgestellt. Anhand einer kombinierten Auswertung der SAR-Daten mit optischen Daten des *Systeme Probatoire d’Observation de la Terre* (SPOT) kann diese Unterbestimmung der Siedlungsflächen verringert werden.

Alle diese Arbeiten zeigen keine Eignung zu einer Automatisierbarkeit. Bei He et al. (2006) ist die Anzahl der Testgebiete zu gering, um auf eine Übertragbarkeit schließen zu können. Die Entwicklungen von Stasolla und Gamba (2008b) werden zwar von Stasolla und Gamba (2008a) auf weitere Sensoren und, in der Folge, von Lisini und Gamba (2008) auf insgesamt sieben TerraSAR-X Datensätze übertragen, doch werden dabei periphere urbane Strukturen nur unzureichend erfasst. Vielversprechend in dieser Hinsicht sind die Entwicklungen von Esch (2006), die gute Ergebnisse liefern, deren Prozessierung allerdings sehr zeitintensiv sind. Aufbauend auf diesen letztgenannten Arbeiten werden im Zuge der hier vorliegenden Dissertationsschrift Methoden zur Erfassung von bebautem Areal (vgl. Abschnitt 4.1) entwickelt, die unüberwacht betrieben werden können.

2

Methodische Grundlagen

In diesem Kapitel werden die methodischen Grundlagen zu den hier vorzustellenden Arbeiten gegeben. Dabei wird zunächst auf die Radarfernerkundung eingegangen und im Anschluss daran relevante Verfahren in der digitalen Bildverarbeitung vorgestellt.

2.1 Grundlagen der Radarfernerkundung

Die hier vorgestellten Arbeiten basieren weitestgehend auf Datensätzen zweier SAR-Sensoren, des deutschen TerraSAR-X sowie, in geringerem Umfang, des japanischen ALOS-PALSAR. In diesem Abschnitt werden zunächst einige Grundlagen der Fernerkundung dargelegt. Im Anschluss auf die Radarfernerkundung und insbesondere das SAR-Prinzip eingegangen. Die Ausführungen basieren, sofern später nicht anders gekennzeichnet, auf den Monographien von Henderson und Lewis (1998), Klausning und Holpp (2000), Hein (2004), Oliver und Quegan (2004), Hanssen (2001), Ulaby et al. (1981) und Ulaby et al. (1986b,c).

2.1.1 Das Messprinzip

Eine kurze und allgemein gehaltene Definition für die Fernerkundung liefert Jensen (2000):

‘Fernerkundung ist die Erlangung von Daten über ein Objekt, ohne mit diesem in Berührung zu stehen.’

Um diese Daten zu erhalten, nutzt die Disziplin der geographischen Fernerkundung im Allgemeinen von der Erdoberfläche reflektierte und emittierte elektromagnetische Strahlung (EMS) als Mittel der Informationsübertragung. Diese wird über geeignete Sensoren quantitativ und qualitativ erfasst. Das ganze Spektrum der EMS wird in Abhängigkeit von der Wellenlänge oder Frequenz in unterschiedliche Spektralbereiche eingeteilt (vergl. Abb. 2.1). Dabei stehen Wellenlänge (λ) und Frequenz




Abbildung 2.1: Einteilung des Spektrums der elektromagnetischen Strahlung in den Bereichen Ultraviolett bis Mikrowellen. Auf Grund ihrer Relevanz für die vorliegende Arbeit ist der Bereich der Mikrowellenstrahlung besonders hervorgehoben.

(f) der EMS in folgendem Verhältnis:

$$c_0 = \lambda * f. \quad (2.1)$$

Die Lichtgeschwindigkeit (c_0) ist dabei eine Naturkonstante von etwa 300.000km/s (Halliday et al. 2003).

Der Wellenlängenbereich zwischen 540nm und etwa 10.000nm wird in der Fernerkundung überwiegend von passiven Sensoren genutzt, die die natürliche Strahlung messen. Dieser Bereich umfasst sowohl das sichtbare Licht (VIS) als auch den Infrarot-Bereich des elektromagnetischen Spektrums (vgl. Abb. 2.1).

Dagegen bildet in der Mikrowellenfernerkundung (Grundlage der hier vorgestellten Arbeiten) der sogenannte Mikrowellenbereich mit Wellenlängen zwischen einem

Millimeter bis zu einem Meter (vergl. Abb. 2.1) die Grundlage der Informationsgewinnung. Dieser Bereich wird auch als RADAR-Bereich (engl. *Radio Detection and Ranging*) bezeichnet. Die natürlich vorkommende Strahlung ist in diesem Bereich sehr gering. Aus diesem Grund werden bei der Nutzung von Mikrowellen in der Regel Systeme verwendet, die sowohl Sender als auch Empfänger der zu betrachtenden EMS sind, so genannte Aktive Systeme (Jensen 2000, Richards und Jia 1999, Albrecht 2001, Lillesand und Kiefer 1994). Aus historischen Gründen wird der Frequenzbereich der Radarstrahlung weiter in mit Buchstaben bezeichnete Bänder definierter Frequenzbreite unterteilt (vergl. Abb. 2.1). In Tabelle 2.1 sind die Frequenz- und Wellenlängenbereiche der Radarbänder detailliert aufgelistet.

Tabelle 2.1: Radarbänder mit ihren Bandbreiten. Quelle: Lillesand und Kiefer (1994), ergänzt auf Basis von Ulaby et al. (1981).

Radarband	Frequenzbereich (f) [GHz]	Wellenlängenbereich (λ) [cm]
<i>P</i>	0,3 - 1,0	30 - 100
<i>L</i>	1,0 - 2,0	15 - 30
<i>S</i>	2,0 - 4,0	7,5 - 15
<i>C</i>	4,0 - 8,0	3,75 - 7,5
<i>X</i>	8,0 - 12,5	2,4 - 3,75
<i>K_u</i>	12,5 - 18,0	1,67 - 2,4
<i>K</i>	18,0 - 26,5	1,1 - 1,67
<i>K_a</i>	26,5 - 40,0	0,75 - 1,1
<i>Q</i>	40,0 - 46,0	0,65 - 0,75
<i>V</i>	46,0 - 56,0	0,54 - 0,65
<i>W</i>	56,0 - 100	0,3 - 0,54

Anfänglich wurden Radarsysteme mit realer Apertur (RAR) verwendet. Diese ermöglichten zunächst die Nutzung des Mikrowellenbereichs zur Erkundung entfernter Objekte. Sie waren technisch zu limitiert, um sich in der Erdbeobachtung durchsetzen zu können. Erst mit der Entwicklung des Prinzips der synthetischen Apertur (SAR) konnte dieser Wellenlängenbereich für die Erdbeobachtung effektiv in Wert gesetzt werden. Die Eigenschaften beider Systemdesigns werden in den folgenden Ab-

schnitten näher erläutert. Dabei werden die Grundlagen, die für beide Radarsysteme identisch sind, am Beispiel des RAR beschrieben.

2.1.2 Radar mit realer Apertur

Die Verwendung des Mikrowellenbereichs der EMS in der Erkundung entfernter Objekte begann Anfang des vorangegangenen Jahrhunderts mit der Detektion von Schiffen und Flugobjekten. Die entwickelten Methoden dienten zunächst rein militärischen Zwecken. Als Relikt aus dieser Zeit sind insbesondere die Aufteilung der Radarbänder sowie deren Benennung zu sehen (vgl. Tab. 2.1).

Wichtige Zusammenhänge der Charakteristika von Radarsystemen werden über die Radargleichung beschrieben. Dabei ist für beide Systemdesigns (RAR und SAR) jeweils eine eigene Radargleichung gegeben.

Radargleichung für RAR Die Radargleichung stellt den Zusammenhang zwischen der von der Antenne ausgesendeten und der wiederum an der Antenne ankommenden Strahlungsleistung dar. Über sie kann bei gegebenen Systemcharakteristika und gegebenem Signal-Rausch-Verhältnis (SNR) eine Abschätzung über die maximal zu erzielende Reichweite ($R_{Z,max}$), also der maximalen Detektionsentfernung, vorgenommen werden. Die Radargleichung für RAR lautet wie folgt:

$$R_{Z,max}^4 = \frac{P_S G^2 \lambda^2 \sigma \tau_p}{k(4\pi)^3 T_{eff} SNR_{min} L}. \quad (2.2)$$

Dabei entspricht P_S der Leistung des gesendeten Signals, G dem Antennengewinn, λ der verwendeten Wellenlänge, k der Stefan-Boltzmann-Konstante, τ_p der Impulsdauer des gesendeten Signals, T_{eff} der effektiven Rauschtemperatur, L dem gesamten Strahlungsverlust von Aussendung bis Registrierung sowie σ dem Radarrückstreuquerschnitt. Die Radargleichung (Formel 2.2) enthält Parameter, deren Ausprägung von Systemeigenschaften bestimmt wird, aber auch solche, die rein statistischer Natur sind. Die Systemparameter sind im Einzelnen:

- Der Antennengewinn G ist ein Maß für den Gewinn, der durch den Einsatz von

Richtantennen gegenüber gleichmäßig über den Raum ausstrahlenden Antennen erzielt wird.

- In der effektiven Rauschtemperatur (T_{eff}) werden alle einzelnen auftretenden Rauschelemente zusammengefasst. Die Einzelkomponenten können hierbei in externe und interne Rauschanteile eingeteilt werden.
- Der Gesamtverlust (L) setzt sich aus systembedingten Verlusten, aus Fluktuationsverlusten (L_f) sowie Verlusten, die auf Grund des Strahlendurchgangs (L_a) durch die Atmosphäre entstehen, zusammen. Die beiden Verlustformen L_f und L_a sind dabei statistischer Natur.
- Die über die Antenne abgestrahlte Leistung (P_S).
- Die Dauer des Sendeimpulses (τ_p). Es gilt

$$B * \tau_p \approx 1, \quad (2.3)$$

wobei B die Bandbreite des Empfängers bezeichnet.

- Die Wellenlänge der ausgesandten Strahlung (λ).

Bei den Parametern der Radargleichung, die rein statistischer Natur sind, handelt es sich im Einzelnen um:

- Der Radarrückstreuquerschnitt (σ) als ein Maß zur Beschreibung des Rückstreuverhaltens von Objekten/Punktzielen. Er hat die Einheit m^2 .
- Das SNR gibt den Quotienten aus der Ausgangsleistung des Signals und dem Rauschen am Empfänger wieder. Dieses Verhältnis muss bei der Suche nach der maximal zu erzielenden Reichweite minimiert (SNR_{min}) werden.
- Die oben bereits erwähnten Verlustformen L_f und L_a sind Maße für den Energieverlust der Strahlung auf dem Weg vom Sensor zur Erdoberfläche und zum Sensor zurück.




Abbildung 2.2: Darstellung der Aufnahmegeometrie eines Radarsystems.

Aufnahmegeometrie Zum besseren Verständnis der nachfolgenden Ausführungen wird an dieser Stelle eine Begriffserläuterung sowie eine Darstellung der Aufnahmegeometrie eines Radarsystems gegeben (Abb. 2.2). Zur Erdbeobachtung erfolgt das Aussenden und Empfangen der Mikrowellenstrahlung quer zur Flugrichtung. Wie in optischen Systemen, ergeben sich zwei grundsätzliche Richtungen: die in Flugrichtung (Azimuth) und die dazu orthogonal stehende Richtung. Letztere wird im Folgenden 'Entfernung' genannt. Einige der später besprochenen Eigenschaften von Radarsystemen werden für Azimuth oder Entfernung getrennt behandelt. In Entfernungsrichtung unterscheidet man den Nahbereich vom Fernbereich. Der Einfallswinkel (θ) der Radarstrahlung nimmt dabei vom Nahbereich zum Fernbereich hin zu. In dieser Arbeit wird zur Vereinfachung lediglich der mittlere Einfallswinkel der entsprechenden Szenen genannt. Die Schrägentfernung bezeichnet die von der Mikrowellenstrahlung zurückgelegte Strecke vom Sensor zur Erdoberfläche und ist somit ausschlaggebend für die Laufzeit der Strahlung.

Geometrische Auflösung Wie auch bei optischen Aufnahmesystemen, ist die geometrische Auflösung des Sensors ein wichtiger Systemparameter. Bei Radarsystemen

wird mit der geometrischen Auflösung die minimale Entfernung von zwei zu detektierenden Punktstreuern am Erdboden bezeichnet, deren Signale getrennt vom System erfasst werden können. In Azimuth-Richtung wird diese Entfernung über die Breite der Hauptkeule des gesendeten Radarimpulses bestimmt. Bei Systemen, die für das Senden und Empfangen die gleiche Antenne verwenden, ergibt sich unter Einrechnung der Entfernung (R_Z) des Punktzieles von der Antenne die Azimuth-Bodenauflösung ($\delta_{a,rar}$) eines Radarsystems aus

$$\delta_{a,rar} \approx 0,64 \frac{\lambda}{d} R_Z, \quad (2.4)$$

mit λ als der verwendeten Wellenlänge und d als Länge der verwendeten realen Antenne.

Die Entfernungsauflösung δ_r ergibt sich entsprechend oben genannter Definition aus der minimalen Distanz zweier in Entfernungsrichtung hintereinander liegender Punktziele, deren Rückstreusignale sich beim Eintreffen im Sensor nicht überlagern. Diese gesuchte Distanz ergibt sich bei Betrachtung entlang des Strahlengangs aus

$$\delta_r = \frac{c_0 * \tau_P}{2} = \frac{c_0}{2 * B}. \quad (2.5)$$

Bei satelliten- bzw. flugzeuggetragenen Systemen zur Erdbeobachtung muss zur Ermittlung der Entfernungsauflösung am Boden (δ_g) zudem noch die geometrische Beziehung der Flughöhe berücksichtigt werden:

$$\delta_g = \frac{c_0}{2 * B * \sin\theta}, \quad (2.6)$$

mit θ dem Einfallswinkel. Aus Formel 2.6 geht hervor, dass die Entfernungsauflösung (δ_g) mit abnehmendem Einfallswinkel besser wird. Dies hat zur Folge, dass Radarsysteme in der bildgebenden Erdbeobachtung nur als Seitsichtradar verwendet werden können. Abbildung 2.3 stellt die Zusammenhänge zur Bestimmung der geometrischen Auflösung von Radarsystemen dar.

Wechselwirkungen mit der Atmosphäre Auf dem Weg durch die Atmosphäre unterliegt die EMS im Allgemeinen verschiedenen Wechselwirkungen. Welcher Art




Abbildung 2.3: Schematische Darstellung der Auflösungszelle in Radarsystemen (weitere Erläuterungen im Text).

diese sind, wird von der Größe und der Beschaffenheit der Bestandteile der Atmosphäre im Verhältnis zum betrachteten Spektralbereich bestimmt. Möglich sind Absorption, Streuung sowie Reflexion der Strahlung.

Im Vergleich zu Strahlung mit kürzerer Wellenlänge sind die Verluste, die durch die Wechselwirkungen mit atmosphärischen Bestandteilen entstehen, bei Radarstrahlung gering. Selbst Wolken, Niederschlag und feste Atmosphärenbestandteile haben (in Abhängigkeit von der Größe der Hydrometeoren) meist nur einen leicht abschwächenden Einfluss auf die am Sensor eintreffende Energie, während sie im Wellenlängenbereich der optischen Sensoren in der Regel zum totalen Informationsverlust im Hinblick auf die Beobachtung der Erdoberfläche führen. Auf Grund dieser Eigenschaften sind Radarsysteme interessante und zuverlässige Werkzeuge in der Erdbeobachtung.

Geometrische Effekte in Radaraufnahmen Die Zuordnung des am Empfänger detektierten Signals zu einer am Erdboden lokalisierten Auflösungszelle errechnet sich über die Laufzeit des Signals. In reliefiertem Gelände führt dieser Umstand zu Verzerrungen in der Bilddarstellung, die auf die Geometrie des Sensor-Oberfläche-Systems zurückzuführen sind. So werden Schrägdächer von Häusern oder auch Berghänge, die dem Sensor zugewandt sind, verkürzt dargestellt (Verkürzung). In erhöhten Lagen ist die Schrägentfernung vom Sensor zum Beobachtungspunkt — bei gleicher Entfer-




Abbildung 2.4: Geometrische Effekte in Radaraufnahmen, die häufig im Kontext urbaner Räume auftreten.

nung vom Nadirpunkt — geringer als in flachem Areal. Im Extremfall, wenn also der lokale Einfallswinkel ϵ_L der Radarstrahlung größer ist als der Depressionswinkel ϵ_D des Objektes, erreicht das Rückstreusignal der Objektspitze den Sensor früher als das Signal des Objektfußes. In diesem Fall findet in der Abbildung des Berges eine 'Umklappung' statt: der Berg 'steht auf dem Kopf' (Überlagerung). Auf der dem Sensor abgewandten Seite eines Daches oder Berghanges können zwei weitere Effekte beobachtet werden. Zum Einen, bei spitzem lokalem Einfallswinkel der Radarstrahlung, eine Objektverlängerung, die sich analog zur Verkürzung auf der dem Sensor zugewandten Seite erklärt. Zum Anderen werden aus Regionen, deren direkte Linie zum Sensor von Hindernissen, wie z. B. Bergrücken oder Gebäuden, verdeckt werden, keine Informationen empfangen. Diese Areale sind als Schattenflächen (Radarschatten) in der Aufnahme zu erkennen (Abb. 2.4).

Neben diesen Effekten spielen insbesondere Mehrfachreflexionen und Abschattungen in urbanen Räumen eine verstärkte Rolle. Sie sind auf die speziellen geometrischen Formen innerhalb von Städten zurückzuführen. Da sie für diese Arbeit eine geringe Relevanz besitzen, werden sie nicht weiter erläutert.

Wechselwirkungen mit Objekten Das Rückstreuverhalten verschiedener Objekte in der Erdbeobachtung (als Objekte werden an dieser Stelle sowohl einzeln abgegrenzte Objekte wie z.B. Bäume und Häuser, als auch Geländeformationen wie Gewässer, Ackerflächen u.ä. verstanden) wird neben der Aufnahmegeometrie (z.B. Blickrichtung, -winkel, Objektgeometrie) auch von den Material- und Oberflächeneigenschaften der Objekte bestimmt. Im Hinblick auf die Materialeigenschaften wird die Rückstreuung insbesondere von der dimensionslosen Di-Elektrizitätszahl κ bestimmt. Diese Zahl beschreibt die Eigenschaft eines Materials im Hinblick auf seine Durchlässigkeit für ein elektrisches Feld. Je höher dieser vom Material abhängige Wert, desto höher die Reflexion und — in der Regel — auch die Rückstreuung. Wasser besitzt einen sehr hohen Wert für κ aus. Dieser ist mit ca. 80 etwa um das Siebenfache größer als der Wert für Glas. Die Referenz bildet das Vakuum mit exakt eins (Halliday et al. 2003, Vogel 1999).

Neben κ hat auch die Oberflächenrauigkeit von Objekten einen starken Einfluß auf die Radarrückstreuung. Zur Bewertung der Rauigkeit dient das modifizierte *Rayleigh*-Kriterium. Dieses Kriterium unterscheidet Oberflächen, in Abhängigkeit von der Wellenlänge der elektromagnetischen Strahlung λ und θ , in raue Oberflächen, mittlere Rauigkeit und glatte Flächen. Dabei gelten folgende Beziehungen:

$$\sigma_{h,rau} > \frac{\lambda}{4.4\cos\theta} > \sigma_{h,mittel} > \frac{\lambda}{25\cos\theta} > \sigma_{h,glatt}, \quad (2.7)$$

mit σ der Standardabweichung der Höhenunterschiede h der Oberfläche (Lillesand und Kiefer 1994).

Raue Flächen streuen diffuser als glatte Flächen (Abb. 2.5). Das heißt, dass in der Ebene von rauen Flächen in der Regel mehr Strahlung zum Sensor zurückgeworfen wird als dies bei glatten Flächen der Fall ist. An glatten Flächen wird der überwiegende Teil der Strahlung vom Sensor weg gestreut. In Verbindung mit in Entfernungsrichtung angrenzenden Objekten mit vertikaler Ausdehnung - beispielsweise einer Hauswand - kann so über doppelt gerichtete Streuung eine enorme Rückstreuung erzielt werden. Dieser Effekt wird als *double-bounce* bezeichnet (vergl. Abb. 2.4).

Polarisation In Radarsystemen wird der Wellencharakter der EMS in der Art in Wert gesetzt, dass die ausgesendete Strahlung eine definierte Polarisation besitzt.




Abbildung 2.5: Das Streuverhalten von Radarstrahlen an verschiedenen Oberflächen. Glatte Oberflächen - wie Wasser oder Asphalt - weisen eine gerichtete Streuung vom Sensor weg auf. Im Bild sind diese Flächen durch Bereiche geringer Intensität gekennzeichnet. An rauen Oberflächen wird die Strahlung in den kompletten Halbkugelraum über der Fläche gestreut. Im Blätterwerk von Bäumen findet eine sogenannte Volumenstreuung statt, d. h. die Strahlung wird in den kompletten Raum gestreut.

Durch die Anwendung von Filtern wird entweder Horizontal (H) oder Vertikal (V) polarisierte Strahlung ausgesendet. Ähnlich wird über den Einsatz von Filtern entweder der horizontale oder der vertikale Anteil der von der Erdoberfläche reflektierten Strahlung empfangen. Die Kombination der Sende- und Empfangsmöglichkeiten lässt vier Varianten zu: zwei Co-Polarisierte (HH und VV) und zwei Kreuzpolarisierte (HV, VH). Der erste Buchstabe steht jeweils für die Polarisation bei Aussenden des Signals, der zweite Buchstabe für das empfangene Signal.

2.1.3 Radar mit synthetischer Apertur

Im vorhergehenden Abschnitt wurde u.a. gezeigt, dass die Azimuth-Auflösung bei RAR-Systemen durch die Verlängerung der verwendeten Antenne verbessert werden

kann (Gleichung 2.4). Auf Grund physikalischer Beschränkungen kann die Antenne jedoch nicht beliebig vergrößert werden. Daher sind auch der Verbesserung der Azimuth-Auflösung in RAR-Systemen Grenzen gesetzt. Eine Lösung hierfür wurde im Jahr 1953 erstmals von Carl. A. Wiley in Form einer synthetischen Verlängerung der Antenne (SAR) vorgestellt. Dieses Prinzip nutzt den *Doppler*-Effekt, der in relativ zueinander sich bewegenden Systemen eine Frequenzverschiebung zwischen ausgesendetem und empfangenem Signal beschreibt (Vogel 1999, Jensen 2000). Bei bekannter Aufnahmegeometrie zu einem Punktziel ist die zu erwartende Frequenzverschiebung bekannt. Unter der Voraussetzung, dass dieses Punktziel von mehreren zeitlich versetzt ausgesendeten Impulsen getroffen wird, kann über die kohärente Integration der einzelnen rückgestreuten Signale durch statistische Verfahren eine Verbesserung der Azimuth-Auflösung erreicht werden.

Mit der geometrischen Auflösung wird bei SAR-Systemen, analog zum RAR, die minimale Distanz von zwei Punktzielen, deren Rückstreusignale gerade noch unterschieden werden können, bezeichnet. Dabei ergibt sich bei SAR-Systemen die Entfernungsauflösung δ_g über Formel 2.6, also wie bei RAR-Systemen auch. Die Azimuth-Auflösung zeigt in SAR-Systemen jedoch keine Abhängigkeit mehr von der Wellenlänge und der Entfernung zum Punktziel und ist gegeben über

$$\delta_{a,sar} = n \frac{d}{2}. \quad (2.8)$$

Wobei d die Länge der verwendeten realen Antenne des SAR-Systems sowie n die *number of looks* bezeichnet. Mit zunehmender Antennenlänge wird also bei SAR-Systemen die Azimuth-Auflösung schlechter, im Gegensatz zum RAR. Da mit abnehmender Antennenlänge die Halbwertsbreite der Radarkeule größer wird, werden einzelne Punktziele häufiger überstrichen, und die Länge der synthetischen Apertur nimmt zu. Auf ähnliche Weise erklärt sich die Entfernungsunabhängigkeit zum Punktziel bei der Bestimmung der Azimuthauflösung. Hier wird der Bodenabdruck der Radarkeule mit zunehmender Entfernung breiter, einzelne Punktziele werden mit größerer Entfernung zum Sensor vom System häufiger erfasst und somit im Bild häufiger verrechnet.

Aufnahmemodi Klausing und Holpp (2000) beschreiben drei SAR-Verfahren zur

Datenaufnahme und -verarbeitung. Diese drei Verfahren sind identisch mit denen des TerraSAR-X. Daher sollen sie nachfolgend kurz beschrieben werden.

SAR-Systeme nehmen in der Regel einen Streifen entlang der Flugbahn des Sensors auf (engl. *Stripmap-Mode*, SM). In diesem Modus kann eine verhältnismäßig gute Auflösung erzielt werden, die räumliche Abdeckung ist jedoch gering. Um die räumliche Abdeckung zu vergrößern, erlaubt die Antenne Modifizierungen in der Art, dass sie mehrere in Entfernungsrichtung versetzte Streifen aufnimmt, der *ScanSAR*-Modus (SC). Dabei werden zu den Zeiten t_1 und t_2 nicht ein und derselbe Streifen beleuchtet, sondern jeweils angrenzende Streifen (vgl. Abb. 2.6). Einzelne Punktziele werden dabei seltener beleuchtet, wodurch die geometrische Auflösung geringer wird. Auf diese Art wird die beobachtete Fläche vervielfältigt. Der sogenannte *Spotlight*-Modus (SL) verfolgt das Ziel einen kleineren Raum genauer abzubilden. Bei diesem Modus wird die Antenne über eine weitere Strecke durch elektronische oder mechanische Azimuthnachführung auf die zu betrachtende Region gerichtet. Dadurch wird die Länge der synthetischen Antenne (L_{sa}) des SAR-Systems vergrößert, was nach Umformen und Einsetzen der Formel zur Berechnung von L_{sa}

$$L_{sa} = \frac{R_Z \lambda}{d} \Rightarrow d = \frac{R_Z \lambda}{L_{sa}} \quad (2.9)$$

in Gleichung 2.8 zu

$$\delta_{a,sar} = n \frac{R_Z \lambda}{2L_{sa}} \quad (2.10)$$

führt und eine Verbesserung der Auflösung in Azimuth bedeutet. Beide, SC- und SL-Modus, werden durch die Verwendung sogenannter *phased-array* Antennen ermöglicht. Eine schematische Darstellung der Funktionsweise dieser drei Aufnahmemodi wird in Abbildung 2.6 gegeben.

Bildrauschen und Signal Das rückgestreute Signal wird bei Radarsystemen im Gegensatz zu optischen Systemen sowohl mit der Amplituden- als auch mit der Phaseninformation als komplexes Signal aufgezeichnet, wobei die Amplitudeninformation (A) als Realteil und die Phaseninformation (P) als imaginärer Teil der komplexen




Abbildung 2.6: Schematische Darstellung der Aufnahmemodi eines SAR-Systems.

Zahl abgelegt wird. Die Intensitätsinformation (I), die für die Untersuchungen innerhalb dieser Arbeit ausschließlich genutzt wurde, ergibt sich über

$$I = A^2. \quad (2.11)$$

Für jede Auflösungszelle ergibt sich das Gesamtsignal aus der Summe aller Einzelsignale der Rückstreucentren innerhalb dieser Auflösungszelle. Abbildung 2.7 zeigt das Rückstreuverhalten unterschiedlicher Streuzentren innerhalb einer Auflösungszelle (a) sowie das daraus resultierende Gesamtsignal (b). Die Pfeile stellen Vektoren mit einem Amplituden- und einem Phasenanteil dar. Die Teilabbildung b zeigt die Vektoraddition aller Einzelsignale aus Teilabbildung a sowie den Vektor des resultierenden Gesamtsignals.

Dieses zufällig auftretende Rückstreuverhalten innerhalb einer Auflösungszelle führt auch auf ebenen Flächen zu unterschiedlichen Gesamtsignalen einzelner Pixel. Im entstehenden Bild ist eine kleinräumige Körnung, der sogenannte *speckle*, zu sehen. Abbildung 2.8 verdeutlicht diesen Effekt. Sie zeigt einen Ausschnitt einer TerraSAR-X SM Szene (vgl. Abschnitt 3.2.1), auf der überwiegend landwirtschaftlich genutzte Flächen abgebildet sind. Diese Flächen können als eben angesehen werden. Dennoch weist die Intensitätsinformation der einzelnen Auflösungszellen innerhalb der Felder kleinere und größere Unterschiede in der Amplitude auf; insgesamt folgt




Abbildung 2.7: Zusammensetzung des von einer Auflösungszelle empfangenen Gesamtsignals aus den Einzelsignalen, die von verschiedenen Rückstreuzentren innerhalb der Auflösungszelle zum Sensor reflektiert werden. Alle Pfeile sind als Vektoren zu verstehen, die in der Vertikalen die Amplitudeninformation widerspiegeln und in der Horizontalen die Phaseninformation.

sie einer Rayleigh-Verteilung. Goodman (1976) bezeichnet diesen *speckle* als ein bei SAR-Aufnahmen auftretendes system-inhärentes Rauschen, durch welches die wirkliche Information (sowohl Radiometrie als auch Textur) überlagert wird. Der Einfluss dieses *speckle* lässt sich über die Integration mehrmaliger Messungen ein und derselben Auflösungszelle minimieren (Gierull und Sikaneta 2002). Die Zahl der Blicke (*number of looks*) auf die Zellen wird erhöht. Damit einher geht nach Gleichung 2.8 zwangsläufig eine Verringerung der Bodenauflösung in Azimuth.

Die Rückstreueigenschaften der beobachteten Objekte auf der Erdoberfläche unterscheiden sich stark voneinander. Für die empfangenen Signale ergibt sich daraus ein sehr großer Dynamikbereich. Ihn adäquat in einem Datenformat zu fassen, führt zu sehr großen Datenmengen. Um diesen Dynamikbereich auf ein datentechnisch einfacher zu prozessierendes Maß zusammenzufassen, wird die Quadratwurzel aus der detektierten Intensität (I) als Signal (S) gespeichert (Formel 2.12).

$$S = I^{0,5} \quad (2.12)$$




Abbildung 2.8: *Speckle* in homogen strukturierten Arealen.

Bei der Verwendung von n *looks* berechnet sich die Wurzel-Intensitäts-Szene (*square-root-intensity image*) einer SAR Aufnahme nach Gleichung 2.12 aus

$$S = \left[\frac{1}{n} \sum_k I_k \right]^{0,5}; \text{ mit } k = 1, 2, \dots, n \quad (2.13)$$

2.2 Grundlagen der Bildverarbeitung

2.2.1 Klassifikationsverfahren

Wie in Abschnitt 2.1 dargestellt, spiegelt eine Auflösungszelle in Fernerkundungsdatensätzen denjenigen Anteil elektromagnetischer Strahlung wider, der vom betrachteten Objekt reflektiert wird. Die Übersetzung der spektralen Reflexionswerte und weiterer, aus ihr abgeleiteter Informationen in eine thematische Bedeutung wird mit dem Begriff *Bildklassifikation* bezeichnet. Bähr (2005) definiert sie als 'die Einteilung nicht bekannter Muster zu dem Anwender bekannten Bezeichnungen'.

Die verschiedenen Methoden der Bildklassifikation können, je nach ihrer Arbeitsweise, in unterschiedliche Gruppen eingeteilt werden. Man unterscheidet nach der zu betrachtenden Bildkomponente, zwischen pixelbasierter und objektorientierter Klassifikation (vgl. Abschnitte 2.2.1 und 2.2.2). Je nach Art und Weise, in der vom Inter-

preten die Daten klassifiziert werden, wird zwischen überwachten und unüberwachten Verfahren unterschieden (Richards und Jia 1999), vgl. Abschnitt 2.2.1. Zuletzt kann eine Unterteilung in sogenannte *Fuzzy*- oder harte Klassifikationsverfahren vorgenommen werden, je nachdem wie streng die Klassenzuweisung gehandhabt wird (Jähne 2002), vgl. Abschnitt 2.2.1.

Pixel vs. Objekt Die pixelbasierte Bildklassifikation weist jedes Bildelement auf Grund seiner spektralen (bzw. aus dem Spektrum abgeleiteten) Informationen einer Klasse zu. Die objektorientierte Bildklassifikation hingegen fügt einzelne Bildelemente zunächst zu Objekten bzw. Segmenten zusammen. Die Zuweisung der Klasseninformation geschieht erst auf Basis der entstehenden Objekte (Weidner und Lemp 2005, Definiens 2007, 2008). Im Zuge dieser Arbeiten kommen beide Verfahren, sowohl pixelbasierte als auch objektorientierte Klassifikation, zur Anwendung. Da der Vorgang der Objektbildung bzw. Segmentierung für die hier vorgestellten Arbeiten von besonderer Bedeutung ist, wird er in Abschnitt 2.2.2 ausführlicher beschrieben.

Überwacht vs. unüberwacht Die Unterteilung von Klassifikationsmethoden in überwachte oder unüberwachte Verfahren wird in Abhängigkeit von der Bestimmung der Klassengrenzen im aufgespannten Merkmalsraum vorgenommen. Überwachte Verfahren benötigen zur Bestimmung der Merkmalsgrenzen für jede Klasse entweder Beispiel-Bildkomponenten (Pixel oder Objekte) oder sie müssen sich einer vorhandenen Bibliothek bedienen können. Die Trennungskriterien der Klassen werden sodann anhand statistischer Verfahren auf Basis dieser Beispiele festgelegt (Richards und Jia 1999, Jensen 2000). Unüberwachte Verfahren benötigen keine Beispiele; sie sind in der Lage über statistische Verfahren Cluster im Merkmalsraum zu bilden, die als Klassen ausgewiesen werden. Den gefundenen Klassen muss im Nachhinein eine semantische Bedeutung zugewiesen werden (Canty 2007, Richards und Jia 1999, Lillesand und Kiefer 1994). In dieser Arbeit werden ausschließlich überwachte Klassifikationsverfahren angewandt.

***Fuzzy* vs. diskret** Wird eine Bildkomponente über das Klassifikationsverfahren exakt einer Klasse zugewiesen, so spricht man von einer harten Klassifikation. Dies

geschieht analog zur Booleschen Logik. Für jede Klasse enthält die betrachtete Bildkomponente die feste Zuordnung von entweder zugehörig — gleichzusetzen mit dem Wert 1 in der Booleschen Logik — oder nicht zugehörig (Wert 0) (Jähne 2002).

Die *Fuzzy*-Klassifikation geht hier einen Schritt weiter. Sie gibt für jede Bildkomponente Wahrscheinlichkeiten der Zugehörigkeit zu den Zielklassen an. Jeder Bildkomponente wird für jede Klasse ein Wert im Bereich von null bis eins zugewiesen. Dieser Wert gibt an, mit welcher Wahrscheinlichkeit die Bildkomponente der jeweiligen Klasse angehört (Bähr 2005, Tso und Mather 2001, Definiens 2007, 2008).

2.2.2 Objektorientierte Bildverarbeitung

In der objektorientierten Bildverarbeitung sind nicht einzelne Pixel Gegenstand der Bewertung und Verarbeitung von Bildinformationen, sondern auf Basis der Pixel erstellte Bildobjekte. Ein theoretischer Abriss über die Generierung von Bildobjekten und einiger Standardverfahren hierzu soll in diese Thematik einführen (Abschnitt 2.2.2). Speziell wird auf die *Multiresolution Segmentierung* eingegangen, da sie im Verlauf dieser Arbeiten eine herausragende Bedeutung einnimmt (Abschnitt 2.2.2). Abschließend und zusammenfassend soll auf die Bedeutung von Objekten in der geographischen Fernerkundung urbaner Räume eingegangen werden.

Segmentierungsverfahren

Unter der Segmentierung eines Bildes versteht man seine Aufteilung in einzelne Komponenten. Der Grad der Unterteilung ist dabei von der zu bearbeitenden Fragestellung und vom verwendeten Datensatz abhängig (Gonzalez und Woods 2002). Prinzipiell orientiert sich der Prozess der Bildsegmentierung entweder an gefundenen Ähnlichkeiten im Bild, d.h. angrenzende Bildareale mit ähnlichen Eigenschaften werden zu einem Segment zusammengefasst, oder an Unstetigkeiten, d.h. es werden Kanten oder Ausreißer innerhalb des Bildes gesucht (Gonzalez und Woods 2002, Jähne 2002).

Kantenbasierte Segmentierung Eine Segmentierungsmethode, die sich an Unstetigkeiten im Bild orientiert, ist die auf Kanten basierende Segmentierung. Diese Methode sucht Kanten oder Linien im Bild, die sich durch hohe Gradienten der Grauwerte auszeichnen. In der Regel gestaltet sich die Suche so, dass in einem Durchlauf Kanten nur einer festgelegten Richtung detektiert werden. Über mehrere Läufe können Kanten aller Richtungen erfasst werden. Durch eine anschließende Kombination aller Kanten kann eine komplette Abbildung der Kanten eines Bildes erzeugt werden, die, abschließend, die Grenzen der Objekte bilden (Gonzalez und Woods 2002, Jähne 2002).

Schwellwertbasierte Segmentierung Segmentierungen auf Basis von Schwellwerten zeichnen sich durch kurze Prozessierungszeiten aus. Abhängig von seinem Grauwert, wird jedes Bildelement einer Segmentklasse zugewiesen. Die Klassen werden zuvor durch einen oberen und einen unteren Schwellwert definiert. Zusammenhängende Bildelemente einer Objektklasse bilden jeweils die Segmente. Diese Art der Bildsegmentierung eignet sich am besten für Aufnahmen, die mehr oder weniger deutlich voneinander getrennte Maxima in der Häufigkeitsverteilung der Grauwerte aufweisen (Gonzalez und Woods 2002).

Regionenbasierte Segmentierung Neben der auf Schwellwerten basierenden Segmentierung sind eine Reihe weiterer Methoden zur Bildsegmentierung entwickelt worden, deren Bildaufteilung auf Grundlage von Ähnlichkeiten innerhalb des Datensatzes basiert. Eine von ihnen ist die so genannte *Multiresolution Segmentierung*, die in Abschnitt 2.2.2 näher vorgestellt wird, sowie die beiden im Folgenden vorgestellten Verfahren.

Beim *Region Growing* (Anwachsen von Regionen) werden in einem ersten Schritt sogenannte Saat-Pixel ausgewählt. Diese gelten zunächst als eigenständige Segmente. Im Anschluss daran werden diesen Segmenten schrittweise weitere benachbarte Pixel zugefügt. Dabei wird stets überprüft, ob das auf diese Weise neu entstandene Objekt einem zuvor festgelegten Prüfkriterium entspricht. Das Anwachsen wird so lange fortgesetzt, bis dieses Kriterium nicht mehr auf ein erweitertes Segment zutrifft. Das Segment wird in derjenigen Form behalten in der es dem Prüfkriterium zuletzt

standgehalten hat. Auf diese Art wird das komplette Bild in Objekte unterteilt. Jedes Pixel wird dabei in einer Art 'ist-Teil-von' Beziehung einem Objekt zugewiesen (Gonzalez und Woods 2002, Jähne 2002).

Ein dem *Region Growing* entgegengesetzter Ansatz ist das *Split and Merge* (Teilen und Zusammenfassen). Bei diesem Verfahren wird ein Segment — als initiales Segment wird hierbei das komplette Bild aufgefasst — in eine vorbestimmte Anzahl (N_s) von gleichgroßen Segmenten aufgeteilt, wenn es ein definiertes Homogenitätskriterium nicht erfüllt. Jedes in diesem Schritt gebildete Segment wird erneut auf Homogenität geprüft und gegebenenfalls nochmals unterteilt. Dieser Prozess wird, wenn nötig, so lange fortgesetzt, bis Segmente von der Größe eines Pixels entstehen. Bis zu diesem Punkt wird das Bild in immer kleinere Teile aufgeteilt. Eine besondere Form dieses Verfahrens ist die sogenannte *Quadtree-Segmentierung*, bei der N_s gleich vier ist. Das Zusammenfassen einzelner Objekte wird in der Regel im Anschluss an jeden einzelnen Teilungsprozess vorgenommen. Dabei werden ähnliche Objekte, also Objekte, die nach einem temporären Zusammenschluss das Homogenitätskriterium erfüllen, wieder zusammengefasst. Dabei können auch Objekte unterschiedlichen Teilungsgrades, also unterschiedlicher Größe, miteinander zu einem neuen Objekt verbunden werden (Gonzalez und Woods 2002, Jähne 2002).

Multiresolution Segmentierung

Die Bildsegmentierung in dieser Arbeit basiert auf der sogenannten *Multiresolution Segmentierung*, ein Konzept, dass von Baatz und Schäpe (2001) vorgestellt wird. Es basiert auf dem Anwachsen von homogenen Regionen innerhalb eines Bilddatensatzes und entspricht damit einem *Region-Growing*-Verfahren (vgl. Abschnitt 2.2.2). Das Prüfkriterium, in diesem Fall *Heterogenitätskriterium* genannt, anhanddessen das Wachstum der Regionen gesteuert wird, setzt sich aus der Kombination dreier wählbarer Parameter zusammen (vgl. Gleichungen 2.14 bis 2.18). Im Einzelnen wird für jedes Pixel, das in ein bereits bestehendes Objekt integriert werden soll, überprüft, ob durch die Hinzunahme dieses Pixels die Heterogenität des Objektes größer wird, als es durch das Prüfkriterium erlaubt ist. Das Prüfkriterium errechnet sich dabei aus einem vom Anwender eingestellten *Scale-Parameter*.

Die Heterogenität eines Objektes wird anhand des wie folgt definierten Fusionswertes (S_f) berechnet:

$$S_f = w_s h_{cl} + (1 - w_s) h_{sc} \quad (2.14)$$

mit w_s , einem vom Nutzer zu setzenden Gewichtungsfaktor, h_{cl} dem Farbheterogenitätskriterium sowie h_{sc} , dem Formheterogenitätskriterium. Das Farbheterogenitätskriterium ergibt sich dabei aus

$$h_{cl} = \sum_b w_b * \sigma_b, \quad (2.15)$$

mit w_b , der Gewichtung und σ_b , der Standardabweichung innerhalb der einzelnen Bänder b . Das Formheterogenitätskriterium setzt sich aus den beiden Heterogenitätskriterien *Smoothness* (h_{sm}) und *Compactness* (h_{cm}) nach Gleichung 2.16 zusammen.

$$h_{sc} = w_f h_{sm} + (1 - w_f) h_{cm} \quad (2.16)$$

mit w_f , dem Gewichtungsfaktor für h_{sm} . Dabei gilt:

$$h_{sm} = \frac{l}{k}, \quad (2.17)$$

sowie:

$$h_{cm} = \frac{l}{\sqrt{n}}, \quad (2.18)$$

mit l , der Länge der Umrandungslinie des Objektes, k , der kürzesten Linie der das Objekt umschließenden *Bounding Box*, und n , der Anzahl der Pixel innerhalb eines Objektes. Sowohl h_{sm} als auch h_{cm} nehmen einen aktiven Einfluss auf die äußere Form der zu bildenden Segmente.

Die Objekte eines Segmentierungsdurchgangs werden in ihrer Gesamtheit als Segmentierungsebene (*Level*) bezeichnet. Zum Teil werden in den hier vorgestellten Methoden mehrere Segmentierungsebenen mit unterschiedlichen Skalen erzeugt. Diese Ebenen bauen aufeinander auf, und zwar in der Art, dass nach Bildung einer ersten Segmentierungsebene diese den Ausgangspunkt für die Berechnung weiterer Segmentierungsebenen darstellt. Dabei kann sowohl ein exaktes Abbild der ersten Ebene

gebildet werden, als auch Ebenen, deren Objekte maximal, bzw. Ebenen, deren Objekte minimal die Größe der Objekte der ersten Ebene besitzen. Neue Segmente innerhalb dieser Ebenen werden entsprechend der oben angegebenen Kriterien nur dann gebildet, wenn ein größerer *Scale-Parameter* den Zusammenschluss von zwei bestehenden Objekten zulässt, oder wenn ein kleinerer *Scale-Parameter* die Aufteilung bestehender Objekte in kleinere Sub-Objekte verlangt (Definiens 2007, 2008), sehr schön veranschaulicht diesen Sachverhalt auch Esch (2006).

Objekte in dieser Arbeit

Die Erkennbarkeit von Objekten ist in der digitalen Bildverarbeitung eine große Herausforderung und daher ein wichtiges Forschungsthema (Gonzalez und Woods 2002). Grundsätzlich muss zunächst die Frage der Objektdefinition beantwortet werden. Aus der Sicht der Bildverarbeitung wird ein Objekt durch Pixel ähnlicher Eigenschaften (z.B. die Grauwerte aller Kanäle) abgebildet. Aus Sicht derjenigen Wissenschaften, die die Bildverarbeitung als Hilfsdisziplin nutzen, kann diese Definition von Bildobjekten unbefriedigend sein. So beispielsweise auch in der geographischen Fernerkundung. Denn weder müssen sich unterschiedliche Objekte zwangsläufig in ihren Bildeigenschaften unterscheiden noch müssen interessierende Objekte ein in sich homogenes Abbild ergeben. Dies trifft auch auf die Radarfernerkundung zu. Abbildung 2.9 zeigt an dem Beispiel des Citytowers in München, vor welchen Herausforderungen die Objekterkennung im Siedlungsraum steht.

Diesen Herausforderungen der Bildsegmentierung wird in der hier vorliegenden Arbeit wie folgt begegnet: Bildobjekte werden auf verschiedenen Verarbeitungsebenen unterschiedlich definiert. Im ersten Segmentierungsschritt werden lediglich Bildelemente mit ähnlichen Eigenschaften zusammengefasst. Dadurch entstehen sogenannte 'Radar-Objekte'. Diese zeichnen sich zwar durch ein homogenes Rückstreuverhalten aus, besitzen aber nicht zwangsläufig eine semantische Bedeutung. In den darauf folgenden Klassifizierungsschritten werden diese Objekte zusammengefasst, bis die so verbleibenden Segmente das bebaute Areal abbilden. Auf der letzten Verarbeitungsebene werden somit zusammenhängende Gebiete einer Klasse (bebautes Areal/nicht bebautes Areal) im Ganzen als Objekt verstanden.




Abbildung 2.9: SAR-Objekte im urbanen Kontext. Die Wiedergabe des Citytowers in München in einer TSX SL-HR Szene, vom Radarschatten (a) über den Fußpunkt des Gebäudes (b) und den Eck-Reflexionen an der Fensterkonstruktion (c) bis zur Antenne (d). Die Herausforderung besteht darin, aus diesen Einzelobjekten das reale Objekt 'Gebäude' abzuleiten.

2.2.3 Veränderungsanalysen

Veränderungsanalysen (*change detection*) sind ein wichtiges Instrument der geographischen Fernerkundung (Dekker 2005). Sie ermöglichen Aussagen über Art und Ausdehnung von Veränderungen innerhalb eines beobachteten Landschaftsausschnittes zwischen zwei oder mehreren Aufnahmezeitpunkten. In dieser Arbeit werden Veränderungsanalysen zur Identifikation von Baustellen innerhalb von Siedlungsräumen durchgeführt.

Methoden der Veränderungsanalyse für SAR-Daten

In der Literatur werden grundsätzlich zwei Verfahren der Veränderungsanalyse unterschieden: die Differenzmethode und die Post-Klassifikationsmethode (Derrode et al. 2003, Albertz 2001, Jensen 2000). Die Differenzmethode (auch *pre-classification*) fokussiert auf den Grauwertunterschieden zwischen den verwendeten Aufnahmen. Dabei muss berücksichtigt werden, dass neben den realen Veränderungen in dem abgebildeten Gebiet auch unterschiedliche Atmosphären- und Strahlungsbedingungen

eine Rolle spielen. Die Anwendung dieser Methode auf Bilddaten unterschiedlicher Sensoren ist auf Grund unterschiedlicher Radiometrien und Bandbreiten meist nicht oder nur erschwert durchführbar. Die Post-Klassifikationsmethode hingegen erlaubt dies. Dabei werden die Bilddaten zunächst jede für sich klassifiziert, d. h. es können auch unterschiedliche Klassifikationsverfahren zur Anwendung kommen. Die Veränderungsanalyse erfolgt auf Basis der erstellten Klassifikation (Derrode et al. 2003). Neben der reinen Feststellung der Veränderung kann zugleich ihre Charakterisierung vorgenommen werden. Trotz der engen Abhängigkeit von der Klassifikationsgüte der jeweiligen Zeitschnitte, ist dieses Verfahren für die meisten Anwendungen in der geographischen Fernerkundung das am besten geeignete (Albertz 2001).

Für SAR-Daten können die Verfahren zur Veränderungsanalyse weiter in so genannte *Amplitude Change Detection* (ACD) und *Coherent Change Detection* (CCD) Methoden unterschieden werden (Scheuchl et al. 2010). Beide gehören den Vorklassifikationsmethoden an. Die CCD analysiert die interferometrische Kohärenz zweier Datensätze, deren Aufnahmeparameter identisch sind. Die ACD vergleicht die Amplitudeninformation der untersuchten Datensätze. Dekker (2005) bewertet fünf Methoden zur Veränderungsanalyse auf Basis von SAR-Daten und stellt heraus, dass Post-Klassifikationsverfahren für SAR-Daten wenig geeignet sind. Besser eignen sich Methoden, die auf den Ausgangsdaten aufsetzen und den ACD zuzuordnen sind.

***Curvelet*-basierte Veränderungsanalyse**

In der hier vorgestellten Arbeit wird ein nicht-kohärentes Verfahren zur Veränderungsanalyse, wie es von Schmitt et al. (2009, 2010) beschrieben wird, verwendet. Diese Methode zeigt in den vorgestellten Tests eine besondere Eignung zur Analyse von Veränderungen in städtischen Räumen (Schmitt et al. 2010). Grundlage des Verfahrens ist eine *curvelet*-Analyse, die ursprünglich im Kontext der Bildkompression entwickelt wurde, und deren erstmalige Beschreibung auf Candès und Donoho (1999) zurückgeht. *Curvelets* sind eine zweidimensionale Erweiterung der *wavelets*, die wiederum die Grauwerte eines Bilddatensatzes anhand von Sinus- und Cosinus-Schwingungen zeilenweise wiedergeben. Beide Formen sind somit in der Lage, ganze Bildbereiche anhand weniger Parameter wiederzugeben. Die Abbildung dieser Parameter wird

curvelet-domain des Bilddatensatzes genannt. Die Transformation der Bildinformation in die *curvelet-domain* kann auf unterschiedlichen Skalen vorgenommen werden — ein Umstand, den sich Schmitt et al. (2009, 2010) für die Veränderungsanalyse zunutze machen. Die zufällige Verteilung des *speckle* innerhalb von SAR-Daten (vgl. Abschnitt 2.1) erzeugt kleingliedrige Veränderungen in den Bilddaten ohne eine Entsprechung in der Realität. Solche 'Pseudo-Veränderungen' können über die Auswahl größerer Skalen eliminiert werden. Die Veränderungsanalyse an sich wird innerhalb der *curvelet-domain* umgesetzt. Ihr Ergebnis ist ein Datensatz von identischer Größe zu den Ausgangsbildsätzen, der alle Bildbereiche kennzeichnet, auf denen eine Veränderung erkannt wird.

2.2.4 Texturmaße als Eingangsparameter zur Klassifikation

Die in dieser Arbeit verwendeten SAR-Intensitätsszenen besitzen lediglich *einen* Kanal, nämlich die Intensität. Allein auf Basis dieser Information ist eine Bildinterpretation nur in eingeschränktem Umfang möglich (Esch 2006). Aus diesem Grund basieren die Methoden zur Klassifikation der Landbedeckung, welche in Kapitel 4 vorgestellt werden, auf der Auswertung von Intensitätsinformation *und* Bildtextur.

Texturmaße

Texturmaße dienen im Allgemeinen der Beschreibung der Grauwerte Verteilung innerhalb eines Bilddatensatzes. Sind in einer Szene hohe und niedrige Grauwerte dicht beieinander zu finden, spricht man von einer hohen Textur. Eine niedrige Textur ist in weitestgehend homogenen Szenen oder Bildausschnitten zu finden (Oliver und Quegan 2004). Nach Haralick et al. (1973) stehen Textur und Grauwert eines Bildausschnittes in folgender Beziehung: befinden sich die Grauwerte im Bildausschnitt in einer engen Spanne, so ist der Grauwert das bestimmende Merkmal des Ausschnitts. Sind jedoch größere Unterschiede in den Grauwerten zu beobachten, so ist das bestimmende Merkmal die Textur.

In dieser Arbeit kommen zwei prinzipiell unterschiedliche Verfahren zur Bestim-

mung der Bildtextur zur Anwendung, die nachfolgend näher beschrieben werden. Erstens eine von Ulaby et al. (1986a,b) vorgestellte Methode, die auf dem Prinzip des *coefficient of variation* (C_w) basiert, der sich aus Gleichung 2.19 berechnet.

$$C_w = \frac{\sigma_w}{\mu_w} \quad (2.19)$$

mit σ , der Standardabweichung und μ , dem Mittelwert der Grauwerte innerhalb eines Betrachtungsfensters w .

Zweitens die auf einem grundsätzlich anderen Prinzip aufsetzenden Grauwert-Kookurrenz-Matrizen (GLCM) — *Grey Level Co-occurrence Matrix* — nach Haralick et al. (1973).

Bestimmung der realen Textur

Nach Ulaby et al. (1986a,b) setzt sich die beobachtete Textur (C_w) in einer SAR-Szene aus der realen Textur (C_T) und einer systembedingten Textur (C_F), dem Rauschen, wie folgt zusammen:

$$C_w^2 = C_T^2 C_F^2 + C_T^2 + C_F^2. \quad (2.20)$$

C_T ergibt sich dabei allein aus der Rückstreuung von der Erdoberfläche, während C_F das Systemrauschen wiedergibt.

Im Hinblick auf eine Klassifikation ist C_T von großem Interesse, da sich darin die Information der abgebildeten realen Objekte befindet. Die Beeinflussung durch C_F wirkt sich ungünstig auf die Interpretation aus. Der Einfluss von C_F auf C_T muss so weit wie möglich herausgerechnet werden. Zielgröße dieses Vorverarbeitungsschrittes ist somit C_T . C_w wird aus der Szene nach Gleichung 2.19 abgeleitet, die unbekannte Größe C_F muss approximiert werden.

Abschätzung C_F Zur Abschätzung von C_F finden sich in der Literatur verschiedene Ansätze. Sie kann aus den Bilddaten an sich heraus abgeschätzt (Frulla et al. 2000, Esch et al. 2011) oder theoretisch aus den Metadaten abgeleitet werden. Ein

Verfahren zur theoretischen Herleitung über die *number of looks* (n) stellen (Ulaby et al. 1986a,b) vor:

$$n = n_a * n_r \quad (2.21)$$

Mit n_a , der Anzahl der *looks* in Azimuth- und n_r , der Anzahl der *looks* in Entfernungs-Richtung (vgl. Abschnitt 2.1). Weiter ergibt sich C_F analog zu Gleichung 2.19 aus

$$C_F = \frac{\sigma_F}{\mu_F} \quad (2.22)$$

mit

$$\sigma_F^2 = 1 - \mu_F^2 \quad (2.23)$$

sowie unter Anwendung des Gamma-Gesetzes:

$$\mu_F = \frac{\Gamma(n + 0,5)}{n^{0,5}\Gamma(n)}. \quad (2.24)$$

Die Bestimmung von C_F über Gleichung 2.22 stellt eine erste Schätzung dar. Je nach Fragestellung kann diese zu ungenau sein, um den Anforderungen gerecht zu werden. In diesem Fall besteht die Möglichkeit, C_F über die Beschreibung der in der Szene beobachteten Texturen abzuschätzen (Frulla et al. 2000). In Anlehnung an Frulla et al. (2000) wird in dieser Arbeit die Methode wie von Esch et al. (2011) beschrieben angewendet: C_F wird ermittelt, indem für eine Reihe kleinerer Bildbereiche (Fenster) die Beziehung von Standardabweichung zu Mittelwert in einem Scatterplot dargestellt (vgl. Abb. 2.10) wird. In kleinen Intervallen des Mittelwertes ($\delta\mu_w$) wird der niedrigste Wert der Standardabweichung ($\sigma_{w,min}$) gesucht. Auf Basis der so gefundenen Datenpaare μ_w mit korrespondierendem $\sigma_{w,min}$ wird eine lineare Regression durch den Nullpunkt geschätzt. Die Steigung der Regressionsgleichung gibt den Schätzwert für C_F (Esch et al. 2011). Grundannahme dieser Methode ist, dass C_F sowohl in niedrigen als auch in hohen Bereichen der Intensität im gleichen Maße C_T beeinflusst, dem Konzept des multiplikativen Rauschens entsprechend (Ulaby et al. 1986b,a).




Abbildung 2.10: Methodik zur Bestimmung des Bildrauschens nach Esch et al. (2011). In engen Intervallen des Mittelwertes ($\delta\mu_w$) wird jeweils das Minimum der Standardabweichung ($\sigma_{w,min}$) gesucht. Für die so erhaltenen Wertepaare μ_w zu $\sigma_{w,min}$ wird sodann eine Regressionsgerade durch den Nullpunkt ermittelt. Die Steigung dieser Geraden gibt den Wert für C_F .

Abschätzung C_T Da nun sowohl C_F als auch C_w bekannt sind, ergibt sich C_T nach Umformung von Gleichung 2.20 wie folgt:

$$C_T^2 = \frac{C_w^2 - C_F^2}{1 + C_F^2}. \quad (2.25)$$

An dieser Stelle muss darauf hingewiesen werden, dass mit keinem der zuvor besprochenen Schätzverfahren zur Bestimmung von C_F ein absolutes Minimum dieser Textur gefunden werden konnte. Das hat zur Folge, dass nach Gleichung 2.25 \bar{C}_T^2 negative Werte annehmen kann, da in solchen Fällen der Zähler negativ wird, die weitere Berechnung von C_T wird dadurch unzulässig. Alle weiteren Schritte dieser Arbeit basieren daher auf C_T^2 .

Auf kleinen Fenstern w zeigt die Berechnung von C_T^2 einige Unzulänglichkeiten, die sich bei der weiteren Klassifikation als störend herausstellen. So nimmt C_T^2 in Bereichen der Klasse 'Offenland' in denen Felder mit höherer Rückstreuung an Felder mit niedriger Rückstreuung grenzen, hohe Werte an, während im Zentrum dieser

Felder C_T^2 niedrig ist. Diese Fehler werden durch eine anschließende Mittelwertbildung auf einem vergleichsweise großen Betrachtungsfenster nach

$$\bar{C}_T^2 = \frac{1}{k} \sum_{p=1}^k (C_T^2)_p \quad (2.26)$$

verringert, wobei k die Anzahl der Bildelemente p in dem gegebenen Fenster wiedergibt.

Vereinfachte Bestimmung von C_T Eine einfachere Methode zur Bestimmung von C_T wird von Esch et al. (2010) vorgestellt. Dabei wird C_F grob über den Kehrwert der Summe aus den *looks* (n) in Azimuth- (a) und Entfernungsrichtung (r) (Gleichung 2.27) bestimmt. Diese Methode zeigt eine gute Eignung für TSX-SM Daten.

$$C_F = \frac{1}{n_a + n_r} \quad (2.27)$$

C_T wird anschließend über die Differenz von C_w und C_F bestimmt:

$$C_T = |C_w - C_F| \quad (2.28)$$

Auch bei der Anwendung dieser Abschätzung von C_T erfolgt im Anschluss eine räumliche Mittelung der C_T -Werte. Analog zu Gleichung 2.26 berechnet sich diese Mittelung nach:

$$\bar{C}_T = \frac{1}{k} \sum_{p=1}^k (C_T)_p \quad (2.29)$$

Abbildung 2.11 gibt einen Überblick über die Vorgehensweise bei der Berechnung der Texturlayer. Im Zuge der Landbedeckungsklassifikation werden beide Methode zur Abschätzung von C_F — nach Ulaby et al. (1986a) und nach Esch et al. (2011) — auf ihre Auswirkung auf die Klassifikation gegenübergestellt (Abschnitte 4.3 und 4.3).





Abbildung 2.11: Schematische Darstellung des Prozessablaufes zur Ermittlung der Textur-layer. Die Zahlen in Klammern geben die Gleichungen im Text an, nach denen die jeweiligen Berechnungen durchgeführt werden.

GLCM

Die Ermittlung der Texturmaße aus GLCM basiert auf den von Haralick et al. (1973) beschriebenen Methoden. Wie aus Arbeiten von Haralick (1979) und Maillard (2003) deutlich hervorgeht, ist diese Textur-Klasse zur Bildklassifikation sehr gut geeignet.

Die Kookkurrenzmatrix stellt die Häufigkeit von Grauwertnachbarschaften in gegebener räumlicher Beziehung zueinander dar (Abb. 2.12). In welcher räumlichen Beziehung die Bildelemente zueinander betrachtet werden, wird anhand zweier Parameter beschrieben. Die Betrachtungsrichtung α wird in Winkeln angegeben, in der Regel sind dies 0° , 45° , 90° und 135° . Dabei besagt ein Winkel von 0° , dass horizontal benachbarte Bildelemente verglichen werden. 90° würde die Betrachtung von vertikal benachbarten Bildelemente bedeuten. Als zweiter Parameter dient die Entfernung δ . Ein Wert von eins bedeutet, dass in der jeweiligen Betrachtungsrichtung unmittelbar angrenzende Bildelemente analysiert werden (vgl. Abb. 2.12).

Zur Beschreibung der Textur auf Basis der GLCM stellen Haralick et al. (1973) 14 verschiedene Maße zur Verfügung, anhand derer die unterschiedlichen Anordnungen der Grauwerte hervorgehoben werden können. Jedes dieser 14 Maße wertet die Informationen der P-Matrix aus. Diese entsteht durch die Umrechnung der absoluten Häufigkeiten der GLCM in relative Häufigkeiten (Abb. 2.12). Basierend auf aus Literatur und eigenen Voruntersuchungen gewonnenen Kenntnissen (siehe Methodenteil



Abbildungung 2.12: Beispielhafte Darstellung zur Bestimmung der Grauwert-Kookkurrenzmatrix aus einem Bildausschnitt. Links ist ein Ausschnitt eines Bildes dargestellt. Die Zahlen geben die Grauwerte der Bildelemente wieder. Die mittlere Matrix zeigt die aus dem Ausschnitt abgeleitete Kookkurrenzmatrix. Die Zahlen stellen die absolute Häufigkeit vorkommender Grauwert-Nachbarschaften ($\delta = 1$) in der Horizontalen ($\alpha = 0^\circ$) dar. Rechts ist die aus der Kookkurrenzmatrix berechnete Wahrscheinlichkeitsmatrix (P-Matrix) abgebildet.

Abschnitt 4.4) werden von den 14 bei Haralick et al. (1973) vorgestellten Maßen in dieser Arbeit lediglich die Maße *Contrast* (CON), *Dissimilarity* (DIS) sowie *Correlation* (COR) zur Klassifikation verwendet. Insbesondere die Arbeiten von Clausi (2002) liefern eine gute Ausarbeitung zur Anwendung von GLCM-Maßen. Clausi (2002) findet zwar, dass sich ein Set der drei GLCM-Maße CON, COR sowie *Entropy* (ENT) am besten zur Klassifikation eignet, weist allerdings auch darauf hin, dass CON und DIS die besten Klassifikationsgüten liefern, wenn lediglich eines der Maße zur Anwendung kommt. Maillard (2003) stellt heraus, dass *Angular Second Moment* (ASM), CON und COR die am häufigsten zur Klassifikation genutzten Maße sind.

Das GLCM-Maßen CON (Gleichung 2.30) hebt den Kontrast innerhalb eines Bildausschnittes hervor, indem die Wahrscheinlichkeiten der Nachbarschaft bestimmter Grauwerte, unter Berücksichtigung von α und δ , mit dem Quadrat des Grauwertunterschiedes gewichtet werden.

$$CON = \sum_{i,j=0}^{K-1} P_{i,j}(i-j)^2 \quad (2.30)$$

Mit K , der Grauwertquantisierung, oder auch der maximal vorkommenden Anzahl von Grauwerten. i und j bezeichnen die Zeilen und Spalten der abgeleiteten Wahrscheinlichkeitsmatrix (Abb. 2.12).

Ein Maß für die lineare Abhängigkeit der Grauwerte innerhalb eines Bildausschnitt-

tes gibt COR:

$$COR = \sum_{i,j=0}^{K-1} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (2.31)$$

mit μ_i , μ_j , σ_i und σ_j , dem Mittelwert bzw. der Standardabweichung der jeweiligen Zeilen oder Spalten der Wahrscheinlichkeitsmatrix.

Als drittes verwendetes GLCM-Maß gibt DIS ähnliche statistische Informationen wie CON (Clausi 2002). Dabei werden die Werte der Wahrscheinlichkeitsmatrix nicht mit dem Quadrat, sondern mit dem einfachen Grauwertunterschied gewichtet (Gleichung 2.32).

$$DIS = \sum_{i,j=0}^{K-1} P_{i,j} |i - j| \quad (2.32)$$

Nähere Erläuterungen zu den unterschiedlichen GLCM-basierten Maßen finden sich bei Haralick et al. (1973), Hall-Beyer (2007) sowie Baraldi und Parmiggiani (1995).

In dieser Arbeit werden die GLCM-Texturmaße für die Abgrenzung von Baustellen in TSX-SL-HR Daten eingesetzt. Baustellen zeichnen sich durch eine hohe kleinräumige Heterogenität aus. Bereitliegende Baumaterialien und -geräte stellen jeweils unterschiedliche Rückstreucentren dar, die sehr hohe Reflexionen erzeugen, aber auch kleinräumige Schatten liefern. Um die so entstehende 'Unordnung' in den Bilddaten angemessen ansprechen zu können, werden für diese Fragestellung die GLCM-Texturmaße verwendet. Im Gegensatz zu der zuvor vorgestellten Texturbeschreibung (basierend auf C_w) sind die GLCM-Maße in der Lage, die unterschiedliche Anordnung der Grauwerte innerhalb des Betrachtungsfensters zu unterscheiden (vgl. Abb. 2.13).

Bildausschnitt	A					B				
	1	0	2	1	1	3	2	2	1	0
	1	1	2	0	2	3	2	2	1	0
	3	2	0	1	0	2	2	1	1	0
	0	0	2	1	2	2	1	1	0	0
	3	1	2	0	0	1	1	0	0	0
C_w	0,87					0,87				
GLCM	0,18					0,28				

Abbildung 2.13: Beispiel für die Beschreibung unterschiedlicher Grauwertanordnungen auf Basis von C_w - und GLCM-Maßen. Die beiden Bildausschnitte A und B zeigen gleiche Häufigkeiten der Grauwerte. Sie unterscheiden sich lediglich in ihrer Anordnung. Während die Texturmaße basierend auf dem C_w für das zentrale Bildelement (bei einer Fenstergröße von 5x5) jeweils den gleichen Wert ermitteln, unterscheiden sich die Ergebnisse für das zentrale Bildelement von A und B in den GLCM-basierten Texturmaßen (hier: *Second Angular Moment* (ASM); Fenster: 5x5; $\alpha = 0^\circ$; $\delta = 1$).

3

Untersuchungsgebiet und Datengrundlage

3.1 Untersuchungsgebiet

Urbane Räume zeigen einen Trend zur Ausweitung. Dieser Trend ist eng mit der in der Tendenz steten Zunahme der Erdbevölkerung verbunden, von ca. 3,7 Mrd. im Jahr 1970 auf etwa 6,9 Mrd. im Jahr 2010 (Vereinte Nationen 2011a). Den größten Anteil an dem rasanten Anwachsen der Bevölkerungszahlen haben insbesondere Länder mit niedrigerem Entwicklungsstand. Schätzungen für das Jahr 2015 sagen zwölf von 15 Städten mit den höchsten Einwohnerzahlen in Entwicklungsländern voraus (Paesler 2008). Im Zeitraum 1970 bis 2010 wird der Bevölkerungszuwachs weitestgehend durch die Zunahme der Verstädterung, und damit auch der Zunahme intensiver Raumnutzung, getragen. So gibt Heineberg (2006), Bezug nehmend auf die Vereinten Nationen (UN), für den Zeitraum 1970 bis 2000 eine Zunahme der weltweiten Verstädterung von 36% auf 47% der Erdbevölkerung an, mit einer Zunahme auf 58% bis 2025. Diese Entwicklung führt dazu, dass Veränderungen in dicht besiedelten urbanen Räumen Auswirkungen auf die Lebensqualität und -umstände einer zunehmenden Anzahl von Menschen haben. Ungeachtet der zahlreichen Herausforderungen, die mit dem Stadtleben einhergehen - wie z.B. gesundheitliche Belastung, verändertes Mikroklima (Helbig und Schirmer 1999), Versorgung mit Ressourcen, Emissionsausstoß - spielen Städte somit als Zentren menschlicher Entwicklung eine zunehmend größere Rolle (Gaebe 2004). Gerade die Ressourcenversorgung großer Städte stellt hohe Ansprüche

an Umland und Infrastruktur. So können beispielsweise großräumige Grundwasserabsenkungen um Großstädte beobachtet werden (Scheffer 1998).

Städte weisen, in Abgrenzung von ihrem Umland, vertikale Elemente und klare geometrische Strukturen auf. Innerhalb der Siedlungsräume wiederum kann eine hohe Heterogenität in der Strukturierung der Gebäude beobachtet werden. In Standardmodellen (Paesler 2008, Heineberg 2006, Lichtenberger 1998) zeichnet sich das Zentrum einer Stadt durch hohe Bebauungsdichte mit zugleich vergleichsweise hoher Gebäudestruktur aus. Daran angrenzend finden sich Misch- oder Wohngebiete mit niedrigeren Höhen und stärkerer Durchgrünung. Weiter am Rand der Städte sind in der Regel größere Gewerbegebiete mit ihren flächenmäßig großen Gebäuden mit meist mittlerer Bestandshöhe bei flachen Dächern und weitläufigen Freiflächen angesiedelt (Paesler 2008, Heineberg 2006, Lichtenberger 1998). Punktuell, mitunter auch graduell, wird die gesamte Stadtstruktur von größeren Grünanlagen (Parks, Gärten, Friedhöfe) aufgelockert. Eine Besonderheit von Städten in Entwicklungsländern sind sogenannte informelle Siedlungen oder Slums, deren Lage innerhalb des Siedlungsräums stark variieren kann. Diese sind in der Regel sehr dicht und niedrig bebaut und unterscheiden sich zudem in den für den Ausbau verwendeten Materialien von anderen Strukturtypen.

Urbane Räume bilden das erste Untersuchungsgebiet dieser Arbeit. Damit gemeint sind Städte, ihr direktes Umfeld und ländliche Strukturen, die einem starken modifizierenden Einfluss des Menschen ausgesetzt sind. Auf diesen Untersuchungsgebieten werden im Folgenden Methoden zur Abgrenzung bebauter von unbebauten Flächen sowie zur Landnutzungsklassifikation aus höchstauflösenden SAR-Daten entwickelt. Die zweite Kategorie bildet zur näheren Charakterisierung der Urbanen Räume eine Unterklasse der ersten Kategorie, nämlich Areale innerhalb von Städten, die in einem gegebenen Zeitraum einer Transformation unterliegen. Dies sind vorwiegend Baugebiete, sowohl Neubauten als auch Umbauten, aber auch Bereiche die in ihrer Struktur temporäre Veränderungen erfahren, wie zum Beispiel Straßen, Parkplätze und Halden. Auf den Flächen dieser Kategorie wird untersucht, ob Baugebiete im Siedlungsraum auf Basis von Texturmaßen aus einfach polarisierten höchstauflösenden SAR-Daten identifiziert werden können.




Abbildung 3.1: Übersicht über die Verteilung der Untersuchungsgebiete. Die Kürzel werden in Tab. 3.1 erläutert. Die Hintergrundkarte entstammt der ESRI Datenbank.

Urbane Räume Urbane Räume zeigen weltweit eine große Variabilität im Hinblick auf Bevölkerungszahl, Stadtstruktur und Kulturkreis. Die größte Beachtung in den hier vorgestellten Arbeiten finden großstädtische Agglomerationen mit sehr großer Bevölkerungszahl und hohem Bebauungsgrad, sogenannte Megacities (namentlich: Buenos Aires, Mexiko City, Istanbul, Mumbai, Chengdu und Lagos). Daneben werden auch Großstädte (oder Millionenstädte) wie z. B. München, Sydney, Hyderabad oder Nairobi sowie Mittelstädte (Padang, Ludwigshafen, Potsdam) in die Untersuchungen eingeschlossen. Zuletzt wird als Beispiel für den eher ländlich geprägten Raum mit kleineren Ortschaften das Untersuchungsgebiet Rhein-Neckar-Raum herangezogen (vgl. Abb. 3.1). Somit wird mit der Auswahl der Testgebiete ein weites Spektrum bezüglich der Größe urbaner Agglomerationen abgedeckt.

Im Hinblick auf unterschiedliche Stadtstrukturen fließen sowohl organisch gewachsene Ansiedlungen (z.B. München, Istanbul, Nairobi) als auch im großen Maße auf dem Zeichenbrett geplante Städte (Phoenix, Sydney) in die Untersuchungen ein. Eine Durchmischung unterschiedlicher Wohn- und Gewerbequalitäten wird in der Regel innerhalb einzelner Untersuchungsgebiete erreicht. So kann beispielsweise allein in Hyderabad ein Spektrum vom typischen Slum über höherwertige Wohngebiete bis hin

zum Geschäftszentrum abgedeckt werden. München hingegen kann neben den typischen Innenstadtbereichen mit hohem Versiegelungsgrad und hoher Bebauungsdichte auch stark durchgrünte Wohngebiete mit hohem Baumbestand sowie großflächige Parkanlagen vorweisen.

Eine gute Abdeckung unterschiedlicher Kulturkreise wird zum Einen durch die Auswahl von Städten aller fünf Kontinente gesichert. Zum Anderen wurden auch innerhalb der Kontinente kulturell unterschiedlich geprägte Regionen berücksichtigt. So wurden für Asien neben der stark islamisch-orientalisch geprägten Kultur mit Teheran auch Gebiete der planwirtschaftlich organisierten, in weiten Teilen sehr dicht besiedelten Volkrepublik China (Chengdu) sowie die beiden Städte Hyderabad (Zentralindisch, Hinduistisch, Republik) und Padang (Zentralistisch, Islamisch, Küstenstadt) als Testgebiete untersucht.

Ein weiteres wichtiges Auswahlkriterium für die Testgebiete war die Datenverfügbarkeit. Tabelle 3.1 gibt einen Überblick über die Untersuchungsgebiete, in der für jede Region ein Kürzel zur weiteren Benennung der Untersuchungsräume, deren Verortung auf dem Globus in Abbildung 3.1 dargestellt ist, aufgeführt wird.

Baugebiete Neben der ersten Kategorie der Untersuchungsgebiete, den Urbanen Räumen, wird eine weitere Kategorie, deren flächige Ausdehnung wesentlich geringer ist, untersucht. Auf den entsprechenden Testgebieten wird die Identifizierung von Baugebieten getestet. Zu diesem Zweck werden 14 Areale mit laufender oder geplanter Bautätigkeit innerhalb des Stadtgebietes von München identifiziert und regelmäßig in Feldbegehungen beobachtet. Bei der Auswahl der zu untersuchenden Baugebiete wurde darauf geachtet, Standorte unterschiedlicher Entwicklungsstadien zu finden. Unter 'Entwicklungsstadien' werden in dieser Arbeit die nachfolgenden Baufortschrittsphasen verstanden:

1. Noch keine Aktivitäten
2. Aushub erfolgt
3. Aufbau der Gebäude

Tabelle 3.1: Urbane Räume, auf denen die Identifizierung bebauter Areale und teilweise die Landbedeckungsklassifikation durchgeführt wird sowie die Kürzel, mit denen sie im Weiteren bezeichnet werden.

Testgebiet	Kürzel	Kurzbeschreibung
Buenos Aires (Argentinien)	BUE	Megacity, Küstenstadt
Calabar (Nigeria)	CAL	Mittelstadt, Küstenstadt
Chengdu (VR China)	CTU	Megacity, rasch anwachsend
Gaborone (Botswana)	GAB	Großstadt
Harare (Simbabwe)	HAR	Großstadt
Hyderabad (Indien)	HYD	Millionenstadt, rasch anwachsend
Istanbul (Türkei)	IST	Megacity, Meerengenlage
Kampala (Uganda)	KAM	Großstadt
Lagos (Nigeria)	LOS	Megacity, Küstenstadt
Mexiko City (Mexiko)	MEX	Megacity, Metropole
München (Deutschland)	MUC	Millionenstadt, sehr strukturiert
Mumbai (Indien)	MUM	Megacity, Küstenstadt
Nairobi (Kenia)	NBO	Millionenstadt, rasch anwachsend
Paris (Frankreich)	PAR	Millionenstadt, sehr strukturiert
Potsdam-Berlin (Deutschland)	PBE	Mittelstadt, Millionenstadt
Padang (Indonesien)	PDG	Mittelstadt, Küstenstadt
Phoenix (USA)	PHX	Millionenstadt, sehr strukturiert
Rhein-Neckar (Deutschland)	RNR	Mittelstädte, ländlicher Raum
Sydney (Australien)	SYD	Millionenstadt, Küstenstadt
Teheran (Iran)	THR	Millionenstadt, Gebirgsrandlage

Insgesamt wurden 26 Testgebiete ausgewählt, die sich alle im westlichen Teil des Stadtgebietes von München befinden (vgl. Abb. 3.2). Sie werden in zwei Kategorien eingeteilt. Die Kategorie 'Referenzfläche' umfasst Flächen, die zum 27.01.2009 bei Feldbegehungen als Baugebiet oder potentiell Baugebiet (Brachen, auf denen noch keine Bautätigkeit stattgefunden hat) identifiziert wurden (rote Flächen in Abb. 3.2). Diese Testgebiete, die in Tabelle 3.2 mit der jeweiligen Baufortschrittsphase zum Zeitpunkt der Erstbegehung am 27.01.2009 aufgeführt sind, wurden zu den Terminen 27.01.2009, 04.03.2009 sowie 01.05.2009 vor Ort untersucht.

Der Bereich der 'Theresienwiese', die über weite Teile des Jahres als Parkplatz genutzt wird, wurde diesen Untersuchungen hinzugefügt, da auf diesem Gelände im Laufe des Jahres eine Reihe von größeren Veranstaltungen stattfinden, für die aufwendige Aufbauarbeiten durchgeführt werden. In den Untersuchungszeitraum fällt auf dieser Fläche das jährlich veranstaltete sogenannte Tollwood Winterfestival. Zu dieser mehrwöchigen Festveranstaltung werden große Zelte und kleinere Holzhütten aufgebaut. Auf den Arealen 'Herzog-Ernst-Platz' und 'Marlene-Dietrich-Straße' konnte im Untersuchungszeitraum keine Bautätigkeit festgestellt werden. Diese stellen somit keine Baustellen dar und werden im weiteren Verlauf als Referenzflächen ohne Veränderung betrachtet. Bis auf diese beiden Areale konnten auf allen in Tabelle 3.2 aufgeführten Flächen Veränderungen der Oberflächenstruktur festgestellt werden.

Neben den 'Referenzflächen' gibt es eine zweite Kategorie von Testflächen. Grundlegendes Kriterium für die Auswahl dieser Flächen war eine detektierte Veränderung des Radarrückstreusignals über eine Veränderungsanalyse, die in Abschnitt 2.2.3 näher erläutert wird, und zwar über alle sechs verwendeten TSX-Spotlight Szenen. Hierzu wurden zwölf weitere Flächen ausgewählt. Dabei handelt es sich in vier Fällen ebenfalls um Baustellen, die übrigen acht werden anders genutzt, z. B. als Sportplätze, Wasserflächen oder Parkplätze. Eine Begehung innerhalb des Untersuchungszeitraums fand nicht statt, da die Auswahl dieser Flächen erst nach Beendigung der Veränderungsanalyse vorgenommen wurde. Auf Basis dieser Flächen wird überprüft, inwiefern die Methodik zur Erkennung von Baustellen auch andere Flächen mit beobachteter Veränderung erfasst. Abbildung 3.2 zeigt diese Flächen grün markiert, Tabelle 3.2 benennt sie und ihre Nutzung unter dem Punkt 'Sonstige Veränderungsflächen'.

Tabelle 3.2: Testgebiete der Kategorie 'Veränderungsflächen'. Aufgeführt sind die untersuchten Referenzflächen und deren Baufortschrittsphase zum Zeitpunkt der Erstbegehung zum 27.01.2009, sowie die sonstigen Veränderungsflächen mit ihrer tatsächlichen Nutzung.

Nummer	Bezeichnung	Bauabschnitts- phase / Nutzung	Größe [m ²]
Referenzfläche			
1	Marlene-Dietrich-Straße	1	16.380
2	Theresienwiese	1	376.120
3	Lilli-Palmer-Straße	3	3.720
4	Theresienhöhe	3	15.310
5	Hotel Arnulfpark	3	7.790
6	Herzog-Ernst-Platz	1	9.240
7	Deutsche Bahn (ZOB)	3	13.560
8	Bernhard-Wicki-Straße	2	14.750
9	Arnulfstraße MB	2	9.530
10	Arnulfstraße 51	3	2.780
11	Arnulfstraße 39	3	3.590
12	Donnersberger Brücke	3	16.720
13	Eisnergutbogen	2	18.870
14	Arnulfstr. MB Parkplatz	3	5.630
Sonstige Veränderungsflächen			
15	P Landsberger Straße	Baustelle	12.050
16	Hansastraße	Baustelle	27.950
17	Ganghoferstraße	Baustelle	28.300
18	Dachauerstraße	Baustelle	36.490
19	Sportplatz 1	Sportplatz	5.000
20	Sportplatz 2	Sportplatz	9.020
21	Westpark 1	Wasserfläche	7.620
22	Westpark 2	Wasserfläche	7.580
23	Pappenheimstraße	Lagerfläche	13.220
24	Birketweg	offener Boden	16.400
25	Postzentrum	Parkplatz	19.500
26	Landsberger Straße	Straße	16.720




Abbildung 3.2: Untersuchungsareale im Stadtgebiet von München. In Rot sind die Referenzflächen dargestellt, in Grün sonstige Veränderungsflächen. Die Nummerierung der Testgebiete folgt Tab. 3.2. Als Hintergrund dient eine Ikonos-Aufnahme vom 03.09.2001 in Echtfarbdarstellung (Quelle: Verändert nach Pflöschinger (2010)).

3.2 Radarmissionen

Für diese Arbeiten besonders relevant sind das deutsche Projekt TerraSAR-X und das japanische ALOS-Projekt mit dem PALSAR-Sensor. Zwar sind mit der kanadischen Mission Radarsat-2, dem europäischen Projekt Envisat mit dem Radarsensor ASAR sowie dem von der italienischen Raumfahrtbehörde (*Agenzia Spaziale Italiana*, ASI) betriebene Projekt COSMO-SkyMed weitere Missionen aktiv, diese werden hier aber nicht näher beschrieben.

Anfang 2010 veröffentlichte das *Institute of Electrical and Electronics Engineers* (IEEE) in ihren *Transactions on Geoscience and Remote Sensing* (TGRS) eine Spezialausgabe zum Thema TerraSAR-X. Darin werden neben wenigen angewandten Forschungsergebnissen insbesondere die genauen Spezifika dieses Sensors beschrieben. Der kurze Überblick über die Systemspezifika von TerraSAR-X, der in diesem Unterkapitel gegeben werden soll, basiert auf den Veröffentlichungen von Fritz und Eineder (2008) sowie Werninghaus und Buckreuss (2010), Pitz und Miller (2010), Buckreuss und Schättler (2010), Steinbrecher et al. (2010), Mittermayer et al. (2010b,a), Schwerdt et al. (2010), Bachmann et al. (2010), Bräutigam et al. (2010), Breit et al. (2010) aus der oben erwähnten Spezialausgabe der TGRS. Die Ausführungen zu ALOS-PALSAR in Abschnitt 3.2.2 basieren auf der ALOS Produktformat-Beschreibung (JAXA 2008, 2009).

3.2.1 TerraSAR-X

Der erste deutsche Radarsatellit TerraSAR-X wurde am 15. Juni 2007 in einer Kooperation vom Deutschen Zentrum für Luft- und Raumfahrt (DLR) und der Infoterra GmbH (ITD) gestartet. Nach einer mehrmonatigen Test- und Kalibrierungsphase liefert er seit Anfang 2008 operationell Daten für Wissenschaft und Wirtschaft.

Allgemeines TerraSAR-X befindet sich in einem Orbit in etwa 514km Höhe und bewegt sich in einer sonnensynchronen, polarnahen Umlaufbahn mit einem Inklinationwinkel von $97,4^\circ$. Bei einer realen Antennenlänge von 4,80m und einer typischen

Tabelle 3.3: Zusammenfassung der TerraSAR-X Spezifikationen. Quelle: Fritz und Eineder (2008), Breit et al. (2010)

Sendefrequenz	9,65GHz
Antennenlänge	4,8m
Inklination	97,4°
Revisit Zeit	11 Tage
Bandbreite	150MHz (300MHz experimentell)

Sendebandbreite von 150MHz (300MHz werden experimentell angewendet) erreicht TerraSAR-X je nach Aufnahmemodus (siehe unten) eine geometrische Auflösung zwischen 1m und 16m. Im *Spotlight*-Modus kann eine Auflösung von einem Meter erreicht werden. Der *phased-array* Sensor des TerraSAR-X kann sowohl den Einfallswinkel (zwischen 15° und 60°) als auch die Blickrichtung variieren. Sein volles Leistungsvermögen erzielt er in einem Bereich von 20° bis 55°, eine Variationsmöglichkeit, aufgrund derer eine gegebene Region nach etwa drei Tagen wiederholt aufgenommen werden kann. Werden Blickrichtung und Einfallswinkel nicht variiert, wird eine Wiederholung nach 11 Tagen erreicht. Dabei umrundet der Satellit die Erde ca. 15,2-mal am Tag. Die Sender und Empfänger sind in der Art konzipiert, dass sowohl in Horizontal- (H) als auch in Vertikalpolarisation (V) gesendet und empfangen werden kann. Auf diese Weise sind Aufnahmen in allen vier Polarisationsvarianten (HH, VV, HV, VH) möglich. TerraSAR-X sendet im X-Band mit 9,65GHz; das entspricht einer Wellenlänge von etwa 3cm (Gleichung 2.1 sowie Tab. 2.1 und Tab. 3.3).

Aufnahmemodi des TerraSAR-X TerraSAR-X operiert in den drei Aufnahmemodi *Spotlight*, *Stripmap* sowie *ScanSAR* (vgl. Abschnitt 2.1.3). Der TSX *Spotlight* Modus ermöglicht zudem die Sendebandbreite von 150MHz auf 300MHz zu erhöhen. Damit wird eine weitere Verbesserung der Auflösung erzielt (vgl. Gleichung 2.5). Aufgrund der Azimuth-Nachführung leistet dieser Modus lediglich eine Szenenabdeckung von 10*10km, welche sich bei der experimentellen Verwendung der größeren Bandbreite von 300MHz in Entfernungsrichtung nochmals halbiert. Die geometrische Auflösung im *Spotlight* Modus kann bis zu 1,48*1,7m (Entfernung*Azimuth) betragen,

Tabelle 3.4: Zusammenfassung der Spezifikationen der TerraSAR-X Aufnahmemodi (Quelle: Fritz und Eineder (2008), Breit et al. (2010))

Modus	Spotlight HR	Spotlight	Stripmap	ScanSAR
Szenenabmessungen	5*10km	10*10km	30*50km	100*150km
Einfallswinkel	15°-60° (volle Leistung: 20°-55°)		15°-60° (volle Leistung: 20°-45°)	
Range-Auflösung	0,74-1,77m	1,48-3,49m	1,7-3,49m	1,70-3,49m
Azimuth-Auflösung	1,1m	1,7m	3,3m	18,5m
Polarisation	single	single	quad	single

bei Verwendung der größeren Bandbreite kann diese auf bis zu 0,74*1,1m verbessert werden.

Im *Stripmap* Modus kann, bei einer Kapazität von 1.500km in Azimuth-Richtung, in der Regel eine Fläche von etwa 30*50km überstrichen werden. Dabei wird je nach Anzahl verwendeter Polarisationen eine Auflösung bis zu 1,7*3,3m (*single-pol*) erreicht.

Mit vier Sub-Schwaden wird im *ScanSAR* Modus eine Abdeckung von 100*150km erzielt, bei gleichbleibender Aufnahmekapazität in Azimuth von 1.500km. Die geometrische Auflösung verschlechtert sich auf etwa 1,7*18,5m (*single-pol*). Einen Überblick über die Variationen der einzelnen Aufnahmemodi gibt Tabelle 3.4.

TerraSAR-X Datenprodukte TerraSAR-X Bilddaten werden, soweit es die Georeferenzierung betrifft, in vier Basisprodukten erstellt, unabhängig vom Modus in dem die Daten aufgenommen wurden. Als Standardprodukt und ersten Zwischenschritt zu den weiteren Stufen wird das sogenannte *single-look slant-range complex* (SSC) Bild erzeugt; die Phaseninformation wird darin mitgeliefert. Die Bildregistrierung erfolgt dabei über die Dopplerkoordinaten, die Laufzeit und die GPS-Information am Sensor. Eine erste Verbesserung der Bildregistrierung erfolgt mit dem *multilook ground range detected* (MGD) Produkt. Obschon die Bildinformation auf einen Ellipsoiden projiziert wird, entspricht die Orientierung dieses Produkts, genau wie die des SSC, der

Satellitenflugrichtung. Dieser Orientierungsfehler wird in den beiden nachfolgenden Produkten, dem *geocoded ellipsoid corrected* (GEC) und dem *enhanced ellipsoid corrected* (EEC), korrigiert. Ihre Auslieferung erfolgt in Kartenprojektion. Im Gegensatz zum EEC, wird das GEC-Produkt nicht auf das Gelände korrigiert. Es wird lediglich auf den Ellipsoiden projiziert. Beim EEC erfolgt die Geländekorrektur anhand des im Zuge der SRTM-Mission erstellten Geländemodells (Fritz und Eineder 2008, Breit et al. 2010).

Da TerraSAR-X nicht über den gesamten Bildbereich identische geometrische Auflösungen in Azimuth- und Entfernungsrichtung liefern kann, ist ein weiterer Vorverarbeitungsschritt notwendig, um quadratische Bildelemente zu erhalten. Dieser Schritt ist ganz im Sinne des Datennutzers, der in der Regel einheitliche geometrische Auflösungen bevorzugt. Auf Basis der Gleichungen 2.4 und 2.6 wird die niedrigste Auflösung bestimmt. Auf diese hin wird die bessere Auflösung umgerechnet. Dieser Schritt enthält bereits eine Rausch-Reduzierung: die *number of looks* des entstehenden Produktes (*spatially enhanced*, SE) ist leicht erhöht (Fritz und Eineder 2008, Breit et al. 2010).

3.2.2 ALOS-PALSAR

Allgemeines zu ALOS Der Radar-Sensor *Phased Array type L-band SAR* (PALSAR) ist einer von drei Erdbeobachtungssensoren an Bord der japanischen *Advanced Land Observation Satellite* (ALOS) Plattform. Neben diesem SAR-Sensor führt ALOS noch ein weiteres Instrument zur Erstellung eines Höhenmodells via Stereokartierung im NIR (*Panchromatic Remote-Sensing Instrument Stereo Mapping*, PRISM) mit sich sowie einen multi-spektral Scanner (*Advanced Visible and Near Infrared Radiometer type 2*, AVNIR-2) (JAXA 2008, 2009).

Der Satellit ALOS startete am 24. Januar 2006. Er befindet sich in einer Höhe von etwa 692km in einer sonnensynchronen Umlaufbahn mit einer Inklination von 98,16°. Die Orbitwiederholung wird nach 46 Tagen erreicht. Betrieben wird der Satellit von der japanischen Weltraumbehörde JAXA (*Japan Aerospace Exploration Agency*) mit dem Ziel der Erdbeobachtung, insbesondere um in Krisensituationen

Behörden und Hilfsorganisationen unterstützen zu können. Dabei zeichnet sich ALOS besonders durch die Möglichkeit zur Datenlieferung zu Tag- (AVNIR-2) und Nachtzeiten (PALSAR) aus (JAXA 2008, 2009).

Sensoreigenschaften PALSAR sendet und empfängt EMS im Radar L-Band mit einer Frequenz von 1,27GHz. Die *phased-array* Antenne ermöglicht Aufnahmen mit unterschiedlichen Aufnahmewinkeln, und dies sowohl in horizontaler als auch in vertikaler Polarisation. Der Einfallswinkel der Strahlung kann dabei in einem Bereich von 8° bis 60° variiert werden. Im Streifenmodus wird bei einfachpolarisierten Daten eine geometrische Auflösung von 10m erreicht, bei bi-polaren oder quad-polaren Aufnahmen verringert sich die Auflösung auf 20m. Im SC-Mode erreicht PALSAR eine Auflösung von 100m bei einer etwa fünffachen Flächenabdeckung. Damit kann jährlich eine zwei- bis dreimalige weltweite Abdeckung im Streifenmodus und zudem eine Abdeckung im SC-Modus gewährleistet werden (JAXA 2008, 2009).

Datenprodukte Die Vorverarbeitung der PALSAR-Szenen erfolgt in zwei Stufen. Aus den rekonstruierten, radiometrisch wie geometrisch korrigierten Originaldaten (Level 1.0) werden über die Entfernungs- und Azimuth-Korrektur komplexe Daten in Entfernungsdarstellung generiert (Level 1.1). In Level 1.5 werden diese Daten nach *multi-look* Prozessierung in eine Kartenprojektion überführt. Hierbei gibt es zwei Alternativen: geocodierte Daten (G) oder georeferenzierte Daten (R). Die Intensitätsdaten liegen letztlich in 16-Bit Kodierung vor. Im Streifenmodus deckt eine PALSAR-Szene in Abhängigkeit des Einfallswinkels eine Fläche von 40km bis 70km in Entfernungsrichtung und etwa 51km bis 79km in Azimuthrichtung ab (JAXA 2008, 2009).

3.3 Datenbeschreibung

Zur Methodenentwicklung, -kalibrierung und Ergebnisevaluierung werden in dieser Arbeit verschiedene Datensätze verwendet. Dabei werden Daten der beiden SAR-Sensoren TerraSAR-X und ALOS-PALSAR ausgewertet. Je nach Untersuchungs-

spekt wird auf die Spezifika insbesondere der TSX Daten geachtet. Das Hauptaugenmerk dieser Arbeit liegt auf der Erfassung bebauter Areale. Daher wird diese Methode auf allen Datenprodukten des TSX und auch auf Daten des ALOS-PALSAR getestet, um die Fähigkeit der entwickelten Methode zur Übertragung sowohl auf andere Datenprodukte als auch auf Daten unterschiedlicher Sensoren zu prüfen. Die Übertragung auf unterschiedliche Datenprodukte des TSX zielt dabei, je nach Fragestellung, auf die Anpassung der Methodik auf unterschiedliche Flächenausdehnungen und Detaillierungsgrade. Die Übertragung der Methode auf Datensätze des ALOS-PALSAR dient der Beantwortung der Frage, inwiefern die vorgestellte Methodik von der verwendeten Radarfrequenz abhängig ist.

Die in dieser Arbeit vorgestellten Methoden beruhen entscheidend auf Texturmaßen. Die Verwendung von Datenprodukten mit ursprünglicher Textur ist daher von Bedeutung. In Abschnitt 2.1 wird erläutert, inwiefern die unterschiedlichen Datenprodukte von SAR-Sensoren vorverarbeitet sind. Die hier vorgestellten Methoden werden auf Basis von Datensätzen mit einerseits identischen Abmessungen der Auflösungszellen in beiden Richtungen und andererseits mit geringer Manipulation der ursprünglichen Textur durchgeführt. Unabhängig vom Aufnahmemodus werden TSX Daten der MGD-SE Datenproduktkombination verwendet. Die verwendeten PALSAR Szenen sind geocodierte Level 1.5 Datensätze (vgl. Abschnitte 3.2.1 und 3.2.2).

Die drei Aufnahmemodi von TerraSAR-X ermöglichen die Abbildung von Flächen von etwa 50km^2 (im *Spotlight*-HR-Modus) bis hin zu etwa 2.000km^2 (im *ScanSAR*-Modus). Anhand dieser Datenprodukte können Fragestellungen von ausgeprägt lokalem Interesse bis hin zu regionalen Anwendungen beantwortet werden. Der Detaillierungsgrad verringert sich mit zunehmender Flächenabdeckung. Ein guter Kompromiss aus hoher Flächenabdeckung und guter Detaillierung liefert der Streifen Modus (SM), daher basieren die Hauptuntersuchungen der hier vorgestellten Arbeiten auf diesen Daten. Für 17 Untersuchungsräume wurden insgesamt 21 Datensätze dieses Modus ausgewertet. Diese Daten wurden im Zeitraum vom 06.07.2007 (Rhein-Neckar-Region) bis zum 18.02.2010 (Potsdam-Berlin) überwiegend in HH-Polarisation aufgenommen. Lediglich die Daten von Nairobi und München liegen in VV-Polarisation vor. Der Einfallswinkel der Radarstrahlung variiert bei diesen Daten von $28,7^\circ$ für das Testgebiet Mexiko-City bis $42,9^\circ$ für Paris (genauere Auflistungen der verwendeten

Datensätze finden sich im Anhang in Tab. A.1).

Die Daten des TSX SC-Modus eignen sich aufgrund ihrer enormen Flächenabdeckung (etwa 2.000km²) gut für die Beantwortung regionaler Fragestellungen. Zwei Aufnahmen dieses Datenproduktes wurden in der hier vorliegenden Arbeit verwendet, diese wurden am 25.03.2008 und 15.08.2009 in HH-Polarisation aufgenommen. Die Einfallswinkel der X-Band-Strahlung liegt bei diesen Datensätzen in einer Spanne von 27,4° und 41,9° bei einer geometrischen Auflösung von um die 17m bis 18m in Entfernung und Azimuth. Eine ähnliche Flächenabdeckung zeigen die L-Band Daten des PALSAR-Sensors. Diese Daten wurden am 23.07.2007 (Rhein-Neckar-Region) und 07.04.2008 (Istanbul) mit einem Einfallswinkel von 34,3° aufgenommen. In HH-Polarisation wird dabei eine geometrische Auflösung von etwa 10m erreicht.

Über den SL-HR Aufnahmemodus kann eine höhere Detaillierung erzielt werden. Insgesamt werden zehn Aufnahmen dieses Modus mit variierendem Einfallswinkel zwischen 23,0° und 44,0° verwendet. Die sechs den zentralen Bereich der Stadt München zeigenden Szenen wurden in VV-Polarisation zwischen dem 08.12.2008 und 08.04.2009 bei nahezu identischem Einfallswinkel von etwa 23,0° aufgenommen, alle anderen SL-HR Szenen in HH-Polarisation zwischen dem 28.11.2007 und 17.06.2008. Die geometrische Auflösung der Daten liegt zwischen 1,00m und 1,73m. Neben den Untersuchungen zur Erfassung von Baustellen wird auf diesem Datenprodukt zudem die Übertragung der Methode zur Siedlungserfassung getestet.

4

Klassifikation von Siedlungsräumen in SAR Daten

In diesem Kapitel werden neue Methoden zur Klassifikation höchstauflösender, einfach polarisierter monotemporaler SAR-Daten vorgestellt. Diese Methoden basieren einzig auf der Intensitätsinformation und davon abgeleiteten Texturinformationen.

Zwei Methoden zur Erfassung von bebautem Areal aus TerraSAR-X *Stripmap*-Daten werden vorgestellt. Die erste Methode beinhaltet ein objektorientiertes Verfahren und ist eine Weiterentwicklung der Arbeiten von Esch (2006). Aufbauend auf den Erkenntnissen aus diesem Verfahren, wird als zweite Methode ein neuer pixelbasierter Ansatz entwickelt. Dieser bietet die Vorteile, unabhängig von speziellen Softwarearchitekturen und automatisierbar zu sein, da ein manuelles Eingreifen in den Prozess nicht erforderlich ist. Im Weiteren wird getestet, inwiefern der pixelbasierte Ansatz auf Datensätze der TSX-Aufnahmemodi *ScanSAR* und *Spotlight* (vgl. Abschnitt 2.1) sowie des ALOS-PALSAR übertragen werden kann.

Nach der reinen Abgrenzung bebauten Areals, wird im Anschluss eine neue Methodik entwickelt, um im Umfeld dieser Siedlungsräume die Landbedeckung zu bewerten. Dabei werden, in Anlehnung an die Arbeiten von Bruzzone et al. (2004), vier Basis-klassen, die eine hohe räumliche und zeitliche Übertragbarkeit besitzen, unterschieden. Zuletzt wird eine feinere Charakterisierung des Siedlungsraumes vorgenommen. Der Fokus liegt dabei auf der Erfassung von innerstädtischen Baugebieten, da auf die-

sen Arealen Veränderungen realisiert werden, die vielseitige Auswirkungen auf das Stadtgefüge haben können.

4.1 Erfassung bebauter Areale in TSX *Stripmap*-Daten

Im Folgenden werden Methoden vorgestellt, die der Erfassung bebauten Areals aus TSX-Datensätzen dienen. Hierbei werden die Begriffe *Bebautes Areal*, *Urbaner Raum* und *Siedlungsraum* synonym verwendet. Der Begriff *Siedlungsraum* umfasst allgemein beispielsweise auch Parkanlagen, die aus Sicht der Fernerkundung mit Wald oder Wiese gleichgesetzt werden können. Daher wird an dieser Stelle *Siedlungsraum* als Raum mit vertikaler Bebauung (also *Bebautes Areal*) verstanden. Kleinere Freiflächen und Parkanlagen innerhalb des Siedlungsraumes werden in Abhängigkeit der verwendeten geometrischen Auflösung dem *Bebauten Areal* zugerechnet.

Die entwickelten Methoden basieren auf Intensitäts-, und daraus abgeleiteten Texturinformationen (vgl. Abschnitt 2.2.4). Dabei wird an dieser Stelle zur Bestimmung der Texturinformation das vereinfachte Verfahren nach Esch et al. (2010), wie in den Gleichungen 2.27 bis 2.29 vorgestellt, verwendet.

Primäres Ziel ist es eine Methode zu entwickeln, die weitestgehend ohne manuelles Eingreifen Ergebnisse ermöglicht, die Klassentrennung mit hoher Güte auf allen ausgewählten Testgebieten vorzunehmen. In Teilen sind die entwickelten Methoden und Ergebnisse (Abschnitte 4.1.1 und 4.1.2) bereits bei Thiel et al. (2008a) sowie Esch et al. (2010) veröffentlicht. Andere Teile (Abschnitt 4.2.3) werden von Thiel et al. (2008b) und Esch et al. (2008a) vorgestellt.

4.1.1 Objektorientierter Ansatz

Vor der eigentlichen Klassifikation erfolgt die Berechnung von \bar{C}_T für die gesamte Szene. \bar{C}_T liegt somit für die Klassifikation als eigenständiger Datensatz mit den Dimensionen der originalen Intensitätsdaten vor. Der Klassifikationsalgorithmus basiert im Folgenden auf den Informationen dieser beiden *Layer*.

Das entwickelte schwellwertbasierte Klassifikationsverfahren baut auf einer Reihe von miteinander interagierender Klassen und Schwellwerte auf. In den folgenden Ausführungen werden Abkürzungen für diese Klassen und Parameter verwendet. Um die Lesbarkeit dieser Passage zu erhöhen werden diese Abkürzungen vorab in Tabelle 4.1 zusammenfassend erläutert.

Tabelle 4.1: Abkürzungen (Abk.) der Klassen und Schwellwerte (Param.), die in den Ausführungen zur objekt-orientierten Erfassung von bebautem Areal innerhalb der Bearbeitungsschritte Segmentierung (Segm.) und Klassifikation verwendet werden .

	Klasse	Abk.	Param.	Kriterium
Segm.	Potentiell bebautes Areal	PBA	T_{SD} T_{IS}	Hohe Textur Hohe Intensitätsdifferenz
	Kein bebautes Areal	KBA		Nicht PBA
Klassifikation	Starke urbane Rückstreuer	DBC	T_{DI} T_{DS}	Sehr hohe Intensität Sehr hohe reale Textur
	Urbane Rückstreuer	PUS	T_{PI} T_{PN}	Hohe Intensität Hohe Anzahl GUS im Umfeld
	Urbanes Areal	UA	T_{US}	Hohe reale Textur
			T_{UN}	Hohe Anzahl GUA im Umfeld
			T_{UB}	Hohe Intensität in L1
			T_{BI}	Hohe Intensität
			T_{BS}	Hohe reale Textur
	Von GUA umschlossen	EBU	T_{UB} T_A	Nicht zu niedrige Intensität Genügend große Fläche
Gruppen	Gruppe urbane Streuer	GUS		Vereinigungsmenge $DBC \cup PUS$
	Gruppe urbanes Areal	GUA		Vereinigungsmenge $GUS \cup UA$
	Urbaner Fußabdruck	GUF		Vereinigungsmenge $GUA \cup EBU$

Vorab sei darauf hingewiesen, dass in der objektorientierten Bildverarbeitung selten auf einzelne Pixel zugegriffen wird. Eher wird zur Charakterisierung der Objekte der Informationsgehalt der Gesamtheit der Pixelwerte innerhalb des betrachteten Objektes O_f genutzt. Die hier vorgestellte Methodik verwendet die Objekt-Mittelwerte \bar{O} der Intensität (\bar{O}_I) und der Textur (\bar{O}_C). Diese berechnen sich anhand der Grauwerte der Intensität (I), der Textur (\bar{C}_T) und der Anzahl (n) aller Bildelemente des

Tabelle 4.2: Einstellungen der Parameter, die zur *Multiresolution*-Segmentierung in dieser Arbeit verwendet wurden.

Level	Scale-Parameter	w_b	w_f
L1	150	0,3	0,8
L0	25	0,3	0,8

Objektes wie folgt:

$$\bar{O}_I = \frac{1}{n} \sum_{i=1}^n I_i \quad (4.1)$$

$$\bar{O}_C = \frac{1}{n} \sum_{i=1}^n (\bar{C}_T)_i. \quad (4.2)$$

Methodik Ziel dieser Arbeit ist die Entwicklung einer Methodik, die zu zeitlich und räumlich stabilen Ergebnissen führt. Der objektorientierte Ansatz zur Erfassung von bebauten Arealen folgt dem skizzierten Schema aus Abbildung 4.1. Den ersten Schritt dieses Ansatzes bildet eine grobe Segmentierung auf Basis der Intensitätsinformation (vgl. die *Multiresolution-Segmentierung* in Abschnitt 2.2.2). Diese erste Segmentierung teilt die Szene in verhältnismäßig große Objekte ein. Die Parametereinstellungen für *Scale-Parameter*, w_f sowie w_b folgen dabei der Prämisse, außerhalb des Siedlungsbereiches größere Segmente zu generieren, die keine Überschneidung mit bebauten Bereichen aufweisen. Die Werte dieser Parameter, die über visuelle Vergleiche verschiedener Testrechnungen ermittelt wurden, finden sich in Tabelle 4.2. Auf diesem Weg entsteht die Objektebene *L1* (L für *Level*, Ebene). Alle Objekte (O_{L1}) dieser Segmentierungsebene werden nach (4.3) in die zwei Klassen 'potentielles bebautes Areal' (PBA) und 'kein bebautes Areal' (KBA) eingeteilt.

$$(\bar{O}_C > T_{SD}) \vee (I_{o,max} - I_{o,min} > T_{IS}) \begin{cases} 1 & O_f \in PBA \\ 0 & O_f \in KBA \end{cases} \quad (4.3)$$

Mit $I_{o,max}$, dem höchsten, und $I_{o,min}$, dem niedrigsten Intensitätswert eines Pixels innerhalb des Objektes O_f sowie T_{SD} und T_{IS} den Schwellwerten wie in Tabelle 4.3 gegeben.




Abbildung 4.1: Grafische Übersicht über den Prozessablauf der objektorientierten Methodik zur Detektion von bebauten Arealen aus TerraSAR-X *Stripmap* Daten. Nähere Beschreibungen des Ablaufs sind dem Text zu entnehmen. Quelle: verändert nach Esch et al. (2010)




Abbildung 4.2: Innerhalb der Segmentierungsebene L1 werden nicht alle bebauten Areale in passenden Objekten (in der SAR-Szene oben durch gelbe Umrandungen markiert) abgebildet. Das kleine Gehöft im Zentrum der hier abgebildeten Landschaft im Norden von Dachau ist nach der Segmentierung mit seinem homogenen Umland verschmolzen.

Die verwendeten Schwellwerte wurden über Proberechnungen und visuelle Vergleiche der erzielten Ergebnisse mit optischen Referenzdaten ermittelt (siehe Tabelle 4.3). Die Festlegung dieser Schwellwerte folgte der Prämisse, dass alle Objekte, die bebautes Areal zeigen, als PBA klassifiziert werden. Eine Überklassifizierung von PBA wird an dieser Stelle in Kauf genommen. Mit dem Schwellwert T_{SD} wird dem Umstand Rechnung getragen, dass sich bebaute Areale in SAR-Daten durch eine hohe Heterogenität und damit einer hohen Textur auszeichnen. Mit dem zweiten Schwellwert werden jene Objekte berücksichtigt, in denen vereinzelt stehende Gebäude von homogenem Umland (Äcker und Wiesen) umgeben sind, und daher in den groben Objekten des L1 \bar{O}_C sehr geringe Werte annehmen. Da Gebäude sich jedoch auf Grund von *Corner-Reflexion* und *Double-Bounce* durch eine hohe Rückstreuung auszeichnen, können Objekte, die ein solches Szenario darstellen, über die Differenz $I_{o,max} - I_{o,min}$ identifiziert werden (siehe Abb. 4.2). Nach Abschluss von Segmentierung und Vorklassifizierung bildet die Klasse PBA ein grobes Abbild der bebauten

Areale. Die restlichen Objekte bilden die Klasse KBA.

Die weiteren Analysen fokussieren auf den Objekten der Klasse PBA und sind in Abbildung 4.3 dargestellt. Sie werden mit einer erneuten Segmentierung aller Objekte der Klasse PBA eingeleitet. Die Segmentierungseinstellungen werden solcher Art gewählt (vgl. Tab. 4.2), dass die erzielten Objekte O_{L0} zum einen deutlich kleiner als die Objekte des $L1$ sind. Zum anderen zeigen die Objekte in dieser neu berechneten Segmentierungsebene $L0$ keine Überlappungen mehr zwischen bebautem Areal und nicht bebautem Areal.

Die neuen Objekte O_{L0} bilden die Grundlage zur genaueren Abgrenzung von bebautem Areal: zunächst werden Fokusobjekte O_f ($O_f \in O_{LO}$) identifiziert, deren Rückstreuverhalten dem von bebauten Objekten sehr ähnlich ist, und die sehr wahrscheinlich bebautes Areal (*distinct backscattering centers*, DBC) abbilden. Wie in Abschnitt 2.1.3 dargestellt, zeigen Gebäude aufgrund von Doppel- und Mehrfachreflexion zum einen stark erhöhte Radarrückstreuung, zum anderen ausgeprägte dunkle Areale, die auf Gebäudeschatten zurückzuführen sind. Daher können DBC über die Kombination von besonders hohen Intensitätswerten größer dem Schwellwert T_{DI} sowie eine besonders hohe Textur größer T_{DS} definiert werden:

$$(\bar{O}_I > T_{DI}) \wedge (\bar{O}_C > T_{DS}) \Rightarrow O_f \in DBC \quad (4.4)$$

Diesem ersten Schritt liegt die Annahme zu Grunde, dass jedes bebaute Areal in SAR-Daten durch die Anwesenheit von starken Rückstreuern — hier die Klasse DBC — gekennzeichnet ist. Im Umfeld dieser Objekte werden nun weitere Objekte mit starker Rückstreuung gesucht, die potentiell urbane Strukturen wiedergeben (*potential urban structures*, PUS). Diese Objekte repräsentieren in der Regel ebenfalls Gebäudestrukturen, die auf Grund ihrer Lage im Gelände das Radarsignal weniger intensiv zurückstreuen als Objekte der Klasse DBC . Gründe hierfür können beispielsweise die Abschattung des Direktreflektors am Fußpunkt des Gebäudes oder eine ungünstige Orientierung des Gebäudes zum Sensor sein. Dabei werden sowohl DBC als auch PUS zu einer übergeordneten Klasse Urbane Rückstreuer (*group urban structures*, GUS) zusammengefasst:

$$GUS = DBC \cup PUS \quad (4.5)$$




Abbildung 4.3: Klassifikationsablauf der objektorientierten Methodik auf der Segmentebene L_0 zur Detektion von bebautem Areal am Beispiel der Gemeinden Birkenheide und Maxdorf in der Rhein-Neckar-Region. Teilbild a. zeigt das Intensitäts-Bild. In b. werden die starken urbanen Rückstreuer (*DBC*) in Rot dargestellt. c. zeigt die im Umfeld der *DBC* gefundenen urbanen Rückstreuer (*PUS*). Auf die Abgrenzung des bebauten Areals (*UA*) in d. folgt das Auffüllen der Klassifikationslücken innerhalb des bebauten Areals mit *EBU* (e.), der Zusammenschluss der Klassen zur Sammelklasse 'Gruppe urbaner Fußabdruck' (*GUF*) (f.) und die Glättung der Umrisse des bebauten Areals (g.).

Tabelle 4.3: Schwellwerte (T) zur objektorientierten Erfassung bebauter Areale aus TSX-SM Daten. Es werden individuelle Parametersätze für jedes Testgebiet sowie ein Parametersatz zur automatisierten Prozessierung (global) gegeben.

T	L1		L0									
	SD	IS	DI	DS	PI	PN	US	UN	UB	BI	BS	TA
Global	0,18	300	350	0,18	250	3	0,08	15	55	62	0,8	0,6
BUE	0,2	300	500	0,45	100	3	0,09	7	64	62	0,8	0,6
CTU	0,2	300	500	0,25	200	6	0,1	15	64	62	0,1	0,6
HYD	0,35	0	350	0	300	3	0,3	18	64	62	0,8	0,6
IST	0,35	400	350	0	300	3	0,3	17	64	62	0,8	0,6
LOS	0,2	300	450	0,33	200	3	0,15	15	64	62	0,8	0,6
MEX	0,18	300	350	0,17	250	3	0,08	15	55	62	0,8	0,6
MUC	0,2	300	330	0,25	290	5	0,18	20	64	62	0,8	0,6
NBO	0,18	300	320	0,16	210	3	0,08	15	49	62	0,8	0,6
PDG	0,38	405	520	0	310	15	0,32	33	64	62	0,8	0,3
PHX	0,18	300	350	0,18	250	3	0,08	15	55	62	0,8	0,6
SYD	0,2	300	350	0,18	250	3	0,08	15	64	62	0,8	0,6
THR	0,2	300	600	0,45	200	6	0,18	15	64	62	0,8	0,6

Ein Objekt wird der Klasse *PUS* zugewiesen, wenn sowohl eine hohe Intensität zu verzeichnen ist, als auch in einem Umfeld w_{50} von 50x50 Bildelementen um das jeweilige Objekt eine Anzahl größer T_{PN} von bereits als *GUS* klassifizierten Objekten erreicht wird.

$$(\bar{O}_I > T_{PI}) \wedge (\#GUS_{50} > T_{PN}) \Rightarrow O_f \in PUS \quad (4.6)$$

Dabei wird T_{PI} kleiner gewählt als der zuvor verwendete T_{DI} (vgl. Tab. 4.3). Die Klassifikation der *PUS* wird so lange iteriert, bis keine neuen Objekte gefunden werden, die die Bedingung 4.6 erfüllen. Die absolute Anzahl der als *GUS* klassifizierten Objekte nimmt nach jeder Iteration zu. Somit weitet sich das Bildareal aus, in dem die Objekte auf Zugehörigkeit zur Klasse *PUS* getestet werden.

Im nächsten Schritt wird die Fläche des bebauten Areals (*urban area*, *UA*) um die bereits klassifizierten *GUS*-Objekte umrissen. Dabei werden alle Objekte der Klassen *GUS* und *UA* zu der übergeordneten Klasse *GUA* (*groupe urban area*) zusammenge-

fasst:

$$GUA = GUS \cup UA \quad (4.7)$$

Die Klassifizierung eines Objektes als UA erfolgt, wenn für ein Objekt folgende Bedingungen gelten:

- Ein hoher Wert für \bar{O}_C .
- Eine hohe Anzahl von GUA -Objekte im Umfeld (w_{30}) von 30x30 Bildelementen.
- Ein hoher Wert für \bar{O}_I für das Objekt innerhalb der übergeordneten Segmentierungsebene $L1$, das den gleichen Raum abdeckt (dem sogenannten Superobjekt)

Diese Voraussetzungen werden in Bedingung B_1 zusammengefasst:

$$B_1 = (\bar{O}_C > T_{US}) \wedge (\#GUA_{30} > T_{UN}) \wedge (\bar{O}_I > T_{L1}) \quad (4.8)$$

Um bei diesem Klassifikationsschritt Wasserflächen innerhalb von Siedlungsflächen auszuschließen, gleichzeitig aber Gebäudeschatten nicht fehlzuklassifizieren, wird B_1 eine weitere Bedingung B_2 hinzugefügt.

$$B_2 = (\bar{O}_I > T_{BI}) \vee (\bar{O}_C > T_{BS}) \quad (4.9)$$

Beide Bedingungen B_1 und B_2 müssen zwingend von O_f erfüllt sein, damit das Objekt der Klasse UA zugewiesen werden kann.

$$B_1 \wedge B_2 \Rightarrow O_f \in UA \quad (4.10)$$

In einem letzten Klassifikationsschritt werden alle direkt benachbarten Objekte, die komplett von der übergeordneten Klasse GUA umschlossen sind, zu größeren Objekten zusammengefasst und der Klasse 'von GUA umschlossen' (*enclosed by urban, EBU*) unter folgender Bedingung zugeteilt:

$$(I > T_{UB}) \wedge (A < T_A) \Rightarrow O_f \in EBU \quad (4.11)$$

mit A , dem Flächeninhalt der zusammengefassten Objekte. Diese Schritte sind notwendig, da trotz der Berechnung der Textur auf großen Fenstern kleinere Freiflächen

innerhalb Urbaner Räume niedrige Texturwerte aufzeigen und über die Prozedur nicht als bebautes Areal identifiziert werden (vgl. Abb. 4.3d-e).

Schließlich werden alle Objekte der Klassen *DBC*, *PUS*, *UA* sowie *EBU* zur Sammelklasse 'Gruppe urbaner Fußabdruck' (*GUF*) zusammengeführt:

$$GUF = DBC \cup PUS \cup UA \cup EBU \quad (4.12)$$

Nachbearbeitung Ein letzter Arbeitsschritt dient der Glättung der Randlinien der *GUF*. Zunächst werden alle zusammenhängenden *GUF*-Objekte in große Segmente gefasst. Auf Basis dieser Segmente wird über die Anwendung eines 11x11 Medianfilters die Glättung der Randlinien vollzogen (Abb. 4.3g), es entsteht die Maske 'bebautes Areal' (*BA*).

Übertragbarkeit Um weitere Aussagen über die Robustheit der Methode zu ermöglichen, werden zwei Parameter-Sätze für die einzelnen Szenen getestet. Der erste Satz wird individuell für jedes Testgebiet erstellt, um jeweils eine bestmögliche Klassifikation zu ermöglichen. Der zweite Satz enthält Einstellungen, die in dieser Art identisch auf alle Testgebiete angewendet werden (*Global*). Ein Vergleich der Ergebnisse dieser beiden Parametersätze gestattet erweiterte Aussagen zur Übertragbarkeit der Methode. Darüberhinaus zeigt die Anwendung des globalen Parametersatzes, mit welcher Güte die Methodik ohne manuelles Eingreifen in den Prozessablauf funktioniert.

4.1.2 Pixelbasierter Ansatz

Zielsetzung Neben dem objektorientierten Ansatz wird ein pixelbasierter Ansatz entwickelt. Dieser bietet den Vorteil, im Sinne der Rechenzeit eine bessere Performance zu liefern. Die Grundidee, auf verschiedenen Skalen anhand von Textur und Intensität bebautes Areal von nicht bebautem zu trennen, wird modifiziert, und zur Trennung einzig die Informationen der Textur genutzt.

Grundannahme dieses Ansatzes ist, dass alle bebauten Areale eine hohe Textur aufweisen, da vertikale Strukturen sehr große Kontraste zwischen starken Rückstreuern und abgeschatteten Arealen verursachen.

Methodik Auch hier wurde ein schwellwertbasiertes Klassifikationsverfahren entwickelt, dass auf miteinander interagierender Klassen und Schwellwerte aufbaut. Tabelle 4.4 listet die Abkürzungen dieser Instanzen und Parameter die in den weiteren Ausführungen verwendet werden.

Tabelle 4.4: Abkürzungen (Abk.) der Klassen, Fenster und Schwellwerte (Param.), die in den Ausführungen zur pixel-basierten Erfassung von bebautem Areal verwendet werden.

	Instanz	Abk.	Param.	Kriterium
Klassen	Cluster starker Rückstreuer	DBC	T_{DSL}	Sehr hohe reale Textur SD_{sm}
	Potentiell bebautes Areal	PBA	T_{DSR}	Sehr hohe reale Textur SD_{lg}
			T_{BD}	Hohe Anzahl DBC im Umfeld
			T_{BS}	Hohe Textur SD_{lg}
Fenster	Variantionskoeffizient	cov		Zur Berechnung nach (2.19)
	Kleines Berechnungsfenster	sm		Mittelwert der realen Textur
	Großes Berechnungsfenster	lg		Mittelwert der realen Textur
	Fokusregion	ar		Zählumgebung für DBC
	Majoritätsfenster	maj		Ermittlung der häufigsten Klasse

Vorab zeigt Abbildung 4.4 eine schematische Darstellung der Prozesskette zur pixelbasierten Erfassung von bebautem Areal. Die Vorverarbeitung der Daten beinhaltet die Erstellung zweier Texturlayer. In einem ersten Schritt wird C_w nach Gleichung 2.19 auf einem Fenster w_{cov} von 9x9 Pixel berechnet. C_F wird anschließend nach Gleichung 2.27 und C_T nach Gleichung 2.28, wie von Esch et al. (2010) vorgeschlagen, berechnet. Im Anschluss daran wird C_T über zwei verschiedene Fenster gemittelt (Gl. 2.26): einmal über das Fenster w_{sm} (15x15 Pixel) und einmal über w_{lg} (45x45 Pixel). Die so entstehenden Layer werden im Folgenden mit SD_{sm} und SD_{lg} (SD für *speckle divergence*) bezeichnet. Während SD_{sm} besonders kleinräumige Heterogenitäten hervorhebt, wie sie durch Rückstreuung an Gebäuden und Metallen entstehen, betont SD_{lg} dagegen großflächige Heterogenitäten, wie sie in Siedlungsräumen durch




Abbildung 4.4: Prozessschema zur pixelbasierten Erfassung von 'bebaute Areal'.

den steten Wechsel von sehr starken und mittleren Rückstreuern und Radarschatten entstehen.

Tabelle 4.5: Ermittelte Schwellwerte zur pixelbasierten Erfassung von bebauten Arealen aus TerraSAR-X *Stripmap*-Daten.

Schwellwert (T)	DSL	DSR	BD	BS
Wert	0,4	0,4	10	0,18

Unter der oben genannten Grundannahme wird für jedes Bildelement zunächst geprüft, ob mindestens einer der beiden ermittelten Werte für SD_{sm} oder SD_{lg} größer als die entsprechenden Schwellwerte T_{DSL} bzw. T_{DSR} (Tab. 4.5) ist. Trifft mindestens eine der beiden Bedingungen zu, dann wird für das zentrale Bildelement p_z angenommen, dass es bebautes Areal repräsentiert. Es wird daher als Element der Klasse 'starke Rückstreuer' (DBC) angesehen:

$$(SD_{sm} > T_{DSL}) \vee (SD_{lg} > T_{DSR}) \Rightarrow p_z \in DBC \quad (4.13)$$

Mit diesen beiden Bedingungen werden kleinräumig hoch texturierte Bereiche erfasst. Diese stellen in der Regel starke Rückstreuer neben Schattenbereichen dar, wie sie typisch für die Abbildung von Gebäuden mit ausgeprägtem *Corner*-Reflektor oder *Double-Bounce* in SAR-Aufnahmen sind. Zudem werden Bereiche erfasst, die großflächig sehr heterogen sind. Dies ist meist in städtischen Bereichen der Fall, die auf Grund ihrer Orientierung zum Sensor hin oder bedingt durch starken Baumbestand

keine starken Rückstreuer aufweisen.




Abbildung 4.5: Ablauf der Klassifikationsschritte zur pixelbasierten Erfassung von bebautem Areal. a. zeigt einen Ausschnitt der Intensitätsszene MUC. In b. sind die erfassten starken Rückstreuer (*DBC*) in Rot gezeigt. c. stellt die Abgrenzung des potentiellen bebauten Areals (*PBA*) um die *DBC* herum dar. Die Eliminierung der Ausreißer (grün) ist in d. abgebildet. Nach der Glättung über den Mehrheitsfilter entsteht als Endergebnis die Maske des bebauten Areals (e.).

Die so gefundenen *DBC* repräsentieren in diesem Ansatz sogenannte Saatpixel im Kontext urbaner Räume. Im zweiten Schritt wird für jedes nicht als *DBC* klassifizierte Bildelement abgefragt, ob sich in dessen weiterem Umfeld w_{ar} (99x99 Pixel) eine Anzahl von mindestens T_{BD} *DBC* befinden und für dieses Bildelement ein Wert im *SD_{Ig}-Layer* größer als T_{BS} gefunden wird. Treffen beide Bedingungen zu, wird das entsprechende Pixel als zum potentiell bebauten Areal (*PBA*) zugehörig angesehen.

$$(\#DBC_{ar} \geq T_{BD}) \wedge (SD_{lg} > T_{BS}) \Rightarrow p_z \in PBA \quad (4.14)$$

In diesem Schritt werden um die zuvor gefundenen Saatpixel Flächen mit relativ hoher Textur geformt. Davon ausgehend, dass diese Saatpixel lediglich urbane Streuer abbilden, kann um diese herum das umgebende bebaute Areal abgegrenzt werden. Nun liegt eine Maske vor, die den TSX-*Stripmap* Datensatz in *PBA* und nicht bebautes Areal (*NBA*) einteilt. Die verwendeten Schwellwerte wurden anhand von Vergleichen der jeweils erzielten Ergebnisse ermittelt und finden sich in Tabelle 4.5. Abbildung 4.5 zeigt die einzelnen Klassifikationsschritte beispielhaft anhand eines Ausschnittes im Südosten von München.

Nachbearbeitung In der Nachbearbeitung folgen zwei letzte Prozessierungsschritte. Im ersten Schritt werden kleinräumige Lücken innerhalb des bebauten Areals gefüllt. Dies geschieht über die Erfassung von Arealen, die vollständig von *PBA* umschlossen sind. Daraufhin werden all diejenigen Areale, die eine Fläche von 200m² nicht überschreiten, der Klasse *PBA* zugewiesen. Im zweiten Schritt wird *PBA* nach außen hin geglättet. Dies geschieht durch die Zuweisung eines Bildelementes zur Klasse bebautes Areal (*BA*), vorausgesetzt, in einem Umgebungsfenster w_{maj} (199x199 Pixel) um p_z herum kommt *PBA* häufiger vor als *NBA* (Gleichung 4.15).

$$\#PBA_{maj} > \#NBA_{maj} \begin{cases} 1 & p_z \in BA \\ 0 & p_z \in NBA \end{cases} \quad (4.15)$$

4.2 Übertragung auf SC- und SL-Modi sowie PALSAR

Die im vorangegangenen Abschnitt vorgestellte Methode zur pixelbasierten Erfassung von bebauten Arealen wurde auf Datensätzen des TSX-*Stripmap* Modus entwickelt. Daher ist zunächst von einer Spezialisierung der Methodik auf die Charakteristika dieses Modus, sowohl den verwendeten Frequenzbereich als auch die geometrische Auflösung betreffend, auszugehen. Ziel der folgenden Arbeiten ist es, Kenntnisse über die

Möglichkeiten der Übertragung dieser Methode in Raum, Zeit und Sensorcharakteristik zu erhalten. Für die Tests zur Übertragbarkeit in Raum und Zeit wird das oben vorgestellte pixelbasierte Verfahren in der unüberwachten Variante auf verschiedene Untersuchungsräume bzw. Zeitschnitte angewandt und die Ergebnisse analysiert. Die Tests zur Übertragung auf andere Sensorcharakteristika bedingen verschiedene Anpassungen der Methodik, die nachfolgend beschrieben werden.

4.2.1 TerraSAR-X *ScanSAR*

Aus der veränderten geometrischen Auflösung, die der *ScanSAR*-Modus leistet (vgl. Abschnitt 3.2), ergibt sich die Notwendigkeit zur Anpassung der Schwellwerte und Schätzfenster an die Datensätze dieses Modus. Bei gleichbleibender Fenstergröße würde die verringerte Auflösung die reale Ausprägung der Schätzfenster erheblich vergrößern. Dies erweist sich insbesondere bei der Erfassung kleinerer Ansiedlungen, die umgeben sind von homogenem Gelände (Felder und Wiesen), als Nachteil, da sich hier die Information der Gebäude in der großen Fläche des Betrachtungsfensters verliert. Die Veränderung der Fenstergröße zur Berechnung für C_w führt nach Esch et al. (2011) zu einer Veränderung der über dieses Fenster ermittelten Textur. Esch et al. (2011) finden einen direkten nicht linearen Zusammenhang zwischen der Größe des Berechnungsfensters und der daraus ermittelten Textur C_w .

Mit der Herabsetzung von w_{cov} auf 7x7 Pixel und w_{lg} sowie w_{maj} auf 41x41 Pixel (vgl. Tab. 4.6) kann eine gute Adaption an die geänderte geometrische Auflösung erreicht werden. Hierdurch wird sichergestellt, dass das Umfeld um den jeweiligen Betrachtungsraum nicht zu groß wird. Insbesondere durch Anpassung von w_{maj} von 199x199 auf 41x41 Pixel bleibt das reale Betrachtungsumfeld in etwa identisch (SM: $248,75m^2$; SC: $256,25m^2$). In der Bildverarbeitung ist eine schärfere Trennung von heterogenen zu homogenen Arealen die Folge.

Entsprechend der Anpassung der Betrachtungsumgebungen werden die Schwellwerte DSL , BD und BS geändert. Die Neukalibrierung der Schwellwerte erfolgt anhand wiederholter Anpassungen der Parameter sowie Vergleiche der erzielten Genauigkeiten. Tabelle 4.6 führt alle Fenstergrößen und Schwellwerte auf, die im Zuge der

Übertragung auf den *ScanSAR*-Modus verwendet werden.

Tabelle 4.6: Parametersetting zur Methodenübertragung auf den TSX-*ScanSAR* Modus. Gegenüber dem Ursprungssetting veränderte Parameter sind hervorgehoben.

Parameter	Fenster (w)					Schwellwerte (T)			
	cov	sm	lg	ar	maj	DSL	DSR	BD	BS
Wert	7x7	15x15	41x41	99x99	41x41	0,2	0,4	0,9	2,4

Mit diesen Änderungen ist bereits eine gute Erfassung von bebauten Arealen gewährleistet. Jedoch zeigte sich bei der experimentellen Ermittlung der Schwellwerte und Fenstergrößen, dass dieses Verfahren auf Testgebieten in Küstenlage erhebliche Fehler erzeugt, sobald sie Bildbereiche mit offener See zeigt. Die Rückstreuung von ruhigem Wasser ist in der Regel sehr niedrig; kleinere Schwankungen im Grauwert führen zu einer sehr hohen Textur. Solche Schwankungen entstehen durch Wellengang auf rauer See und übersteigen die Heterogenität, die allein auf Grund des *speckle* entsteht, bei Weitem. Dieser Umstand führt in einem rein auf der Textur aufsetzenden Verfahren zu Fehlklassifikationen. Um die Fehlklassifikation solcher Bildbereiche zu vermeiden, werden die Kriterien zur Klassifikation der Saapixel *DBC* um eine Bedingung erweitert, die die Intensität des zentralen Bildelements p_z abfragt. Diese muss zwingend zu einer der beiden bereits in (4.13) gegebenen Bedingungen erfüllt werden. Somit ergibt sich zur Klassifikation der *DBC* für ScanSAR-Daten folgende Beschreibung:

$$((SD_{sm} > T_{DSL}) \vee (SD_{lg} > T_{DSR})) \wedge (I_{p_z} > T_I) \Rightarrow p_z \in DBC \quad (4.16)$$

4.2.2 TerraSAR-X *Spotlight*

Die Anpassung der pixelbasierten Methodik zur Siedlungserfassung auf die höher aufgelösten Daten des *Spotlight*-Modus bedarf geringerer Anpassungen als für den niedriger aufgelösten *ScanSAR*-Modus. Die Unterschiede in der Kantenlänge der Bildelemente zwischen SM- und SL-Modus sind bei 1,25m respektive 0,50m im urbanen Kontext weniger relevant als der von SM auf SC. Für die Methodenübertragung ist keine Veränderung der Betrachtungsfenster notwendig, lediglich die Anpassung ei-

niger Schwellwerte an die SL-Daten wird vorgenommen. Dies liegt in der größeren Heterogenität — somit auch erhöhten Textur — innerhalb der besser aufgelösten Daten begründet. Tabelle 4.7 fasst die angepassten Schwellwerte zusammen.

Tabelle 4.7: Parametersetting zur Methodenübertragung auf den TSX-*Spotlight* Modus. Gegenüber dem Ursprungssetting veränderte Parameter sind hervorgehoben.

Parameter	Fenster (w)					Schwellwerte (T)			
	cov	sm	lg	ar	maj	DSL	DSR	BD	BS
Wert	9x9	15x15	45x45	99x99	199x199	0,4	0,4	0,7	0,8

4.2.3 ALOS-PALSAR

Zur weiteren Überprüfung der Übertragbarkeit wird die entwickelte Methode zur Erfassung von bebauten Arealen auf Datensätze des PALSAR-Sensors für die Testgebiete Rhein-Neckar-Region (mit den Städten Speyer, Worms, Mannheim, Ludwigshafen) und Istanbul getestet.

Bei der Anwendung der Methodik auf PALSAR Daten muss, neben einer veränderten Auflösung, auch der Einfluss eines anderen Frequenzbereichs berücksichtigt werden. Dabei geht es weniger um ein prinzipiell anderes Verhalten der Bilddaten in Bezug auf Bildrauschen und Reaktion auf geometrische Eigenschaften des abgebildeten Raumes, als vielmehr um partiell verändertes Rückstreuverhalten. Beide Radar-Frequenzbereiche reagieren unterschiedlich auf einzelne Oberflächentypen; insbesondere auf die unterschiedliche Durchdringung von Vegetation sei hingewiesen. Aus dem gleichen Grund wie bei der Anpassung an den SC-Modus (vgl. Gleichung 4.16) wird für PALSAR Daten der Intensitätsschwellwert T_I zur Vermeidung von Fehlklassifikationen bei der Erfassung der *DBC* in Küstengewässern eingesetzt. Der Dynamikbereich der PALSAR Daten unterscheidet sich enorm von den TSX Daten, T_I wird auf den Wert 1000 erhöht.

Des Weiteren führt die verringerte Auflösung, analog zu den Anpassungen auf den SC-Modus, zu einer Verkleinerung der Berechnungsfenster w_{cov} , w_{lg} sowie w_{maj} (vgl. Tab. 4.8). Die Notwendigkeit zur Anpassung dieser Werte liegt zudem in der

Tabelle 4.8: Parametersetting zur Methodenübertragung auf Datensätze des ALOS-PALSAR. Gegenüber dem Ursprungssetting veränderte Parameter sind hervorgehoben.

Parameter	Fenster (w)					Schwellwerte (T)			
	cov	sm	lg	ar	maj	DSL	DSR	BD	BS
neuer Wert	7x7	15x15	35x35	99x99	35x35	0,3	0,15	12	0,06

Verwendung angepasster Schätzfenster begründet. Alle verwendeten Fenstergrößen und Schwellwerte sind in Tabelle 4.8 gelistet.

Auf Grund fehlender Meta-Daten erfolgt die Bestimmung von C_F anhand des automatisierten Verfahrens nach Esch et al. (2011) (vgl. Abschnitt 2.2.4).

4.3 Erfassung einfacher Landbedeckungstypen

In den vorigen Abschnitten wurden neue Methoden zur Erfassung von bebauten Arealen vorgestellt. Nachfolgend wird die Anzahl der Zielklassen erhöht und ein vollautomatisches Verfahren zur Klassifikation von vier Basisklassen anhand von SAR-Daten vorgestellt.

Ziel dieser Arbeit ist die Entwicklung einer übertragbaren operationellen Methodik zur Klassifikation einfachpolarisierter SAR-Daten eines Aufnahmetermins in Basisklassen. In Anlehnung an die Arbeiten von Bruzzone et al. (2004) werden dabei die Klassen 'Siedlungsraum', 'Wald', 'Wasser' und 'Offenland' unterschieden. Diese zeigen aufgrund ihrer physischen Gestaltung die beste räumliche und zeitliche Eignung zur Trennung in SAR-Daten. Die Klasse 'Offenland' in dieser Arbeit entspricht weitestgehend der Klasse 'Felder' bei Bruzzone et al. (2004) und beinhaltet alle in SAR-Szenen sehr homogen erscheinenden Areale, die keiner der anderen drei Klassen zugehören, i.d.R. sind dies Ackerflächen, Wiesen, Straßen, offener Boden. Ein ähnliches Klassifikationsschema wird auch von Dekker (2005) angewandt. Er unterscheidet drei Basisklassen und fasst 'Wasser' und 'Offenland' zu der Klasse 'flaches Areal' zusammen. Vorab wird eine schematische Darstellung der kompletten Klassifikationsmethode in Abbildung 4.6 gegeben.




Abbildung 4.6: Schematische Abbildung der Prozessierungsroutine zur pixelbasierten Landbedeckungsklassifikation aus TSX-Stripmap Daten.

Im Zuge der hier vorgestellten Analysen werden die Testgebiete BUE, CTU, HYD, IST, LOS, MEX, MUC, NBO, PDG, PHX, SYD und THR (vgl. Tabelle 3.1) untersucht. Diese Auswahl sichert eine gute Abdeckung unterschiedlicher Kulturräume und Stadttypen (vgl. Abschnitt 3.1).

Vorverarbeitung Wie für die zuvor beschriebenen Methoden zur Erfassung von Siedlungsräumen, wird auch für die Klassifikation der Basislandbedeckung ein Schwellwertverfahren entwickelt. Die zur Klassentrennung verwendeten Schwellwerte werden automatisiert auf Basis von Histogramm-Auswertungen der Trainingsgebiete gefunden. Aus den zwölf TSX-*Stripmap* Datensätzen der Testgebiete werden für jede Klasse jeweils 100 Trainingsflächen mit einheitlicher Landbedeckung und einer Größe von 100x100 Pixel, im weiteren Verlauf *Chips* genannt, ausgewählt. Die zwölf Testgebiete werden in zwei Kategorien aufgeteilt. Die erste Kategorie dient dem Training der Methode und beinhaltet acht Testgebiete (vgl. Tab. 4.9). Auf den Datensätzen der zweiten Kategorie wird, im Anschluss an das Training, die Klassifikation umgesetzt und bewertet.

Tabelle 4.9: Einteilung der zwölf Testgebiete in zwei Kategorien im Zuge der Landbedeckungsklassifikation.

Kategorie	Training				Klassifikation			
Testgebiet	CTU	HYD	IST	MEX	BUE	LOS	MUC	PDG
	NBO	PHX	SYD	THR				

Die Klassifikation der vier Basis-Klassen wird neben der Intensität auch die räumlich gemittelte Reale Textur (\bar{C}_T^2) nach Esch et al. (2011) (siehe Abschnitt 2.2.4) auswerten. Sie liegt als eigenständiger Datensatz vor.

Methodik Für jede Landbedeckungsklasse werden, basierend auf den *Chips*, Histogramme der Intensität und von \bar{C}_T^2 erstellt. Die Intensität wird dabei in ganzen Graustufen quantisiert, die Textur in Abständen von 0,01. Insgesamt zeigen alle Trainingsgebiete sehr ähnliche Histogramme der LC-Typen, sowohl für die Intensität als auch für \bar{C}_T^2 . Die Histogramme aller Trainingsgebiete sind in den Abbildungen

B.1 und B.2 (siehe Anhang B) abgebildet. Um ein repräsentatives Histogramm zur Bestimmung der Schwellwerte zu erhalten, werden die Histogramme der acht Trainingsgebiete für jede Klasse aufsummiert und normalisiert. So erhält man für jede LC-Klasse eine typische Verteilung der Intensität und der Textur (vgl. Abb. 4.7 und 4.8), auf deren Eigenschaften die Methodik aufbaut.

Die aufsummierten Histogramme der Intensität in Abbildung 4.7 zeigen deutliche Überschneidungen der Klassen 'Offenland', 'Wald' und 'Urbaner Raum'. Diese Histogramme unterscheiden sich lediglich in Höhe und Lage des Maximums sowie der Schiefe nach beiden Seiten. Das Histogramm für den *Urbanen Raum* verläuft deutlich flacher als die der anderen Klassen. Dies deutet auf eine gleichmäßige Verteilung einer großen Spanne von Grauwerten innerhalb dieser Klasse hin, während die Histogramme der Klassen 'Offenland' und 'Wald' sehr ähnliche Verläufe mit einem deutlicher ausgebildeten Maximum zeigen. Das Histogramm der Klasse 'Wasser' hebt sich deutlich von denen der anderen ab. Die 'Wasser'-Intensitätswerte liegen in einem wesentlich engeren und zudem niedrigeren Bereich. Das Histogramm ist sowohl im Anstieg als auch beim Abfallen steiler und zeigt ein deutlich ausgeprägtes Maximum bei etwa 25.




Abbildung 4.7: Histogramme der Intensität der vier Landbedeckungsklassen.

Auf Basis der gleichen *Chips* werden Histogramme für die untersuchten Klassen auf den abgeleiteten Texturdaten (\bar{C}_T^2) erstellt. Die auf diesen Bildausschnitten ermittelten und über alle acht Trainingsgebiete aufsummierten Histogramme sind, in normalisierter Form, in Abbildung 4.8 zu sehen. Die \bar{C}_T^2 -Histogramme zeigen, über alle Klassen gesehen, ein anderes Verhalten als die Verteilungen der Intensitäten (Abb. 4.7). Beispielsweise hebt sich das \bar{C}_T^2 -Histogramm des 'Urbanen Raums' deutlich von dem der anderen Klassen ab: es verläuft deutlich flacher und steigt erst bei höheren \bar{C}_T^2 -Werten an als die der verbleibenden Klassen. Eine Trennung dieser Klasse scheint allein auf Basis der Textur bereits gerechtfertigt zu sein. Diese Erkenntnisse führten bereits zu der in Abschnitt 4.1 vorgestellten Methodik zur Erfassung von Siedlungsräumen.

In Abbildung 4.8 ist zu sehen, dass das \bar{C}_T^2 -Histogramm der Klasse *Wald* sich deutlich von den anderen Klassen unterscheidet: Große Überschneidungen mit den Klassen 'Offenland' und 'Wasser' sind zu beobachten, doch der Verlauf des Histogramms ist trotz ausgeprägtem Maximum flacher, die Schiefe auf beiden Seiten geringer. Für die Klassen 'Wasser' und 'Offenland' hingegen zeigen die Histogramme sehr ähnliche Verläufe; eine Trennung dieser Klassen anhand der Textur ist nicht möglich.




Abbildung 4.8: Verteilung der \bar{C}_T^2 -Werte der Landbedeckungsklassen.

Die Klassentrennung erfolgt pixelbasiert anhand von Schwellwerten, folgt also dem *parallelepiped*-Klassifikationsschema. Diese Schwellwerte werden dabei über die Auswertung der Intensitäts- und \bar{C}_T^2 -Histogramme automatisiert ermittelt.

Die \bar{C}_T^2 -Histogramme zeigen, dass eine Trennung der Klassen 'Siedlungsraum' und 'Wald' von den beiden sich ähnlichen Klassen 'Wasser' und 'Offenland' gut, aber nicht ausreichend, auf Grundlage der Textur vorgenommen werden kann. Um die Trennungsqualität weiter zu steigern und zudem *Wasser* von *Offenland* zu unterscheiden, wird als weiteres Klassifikationskriterium die Intensität hinzugenommen. Die Histogramme der Intensität zeigen, dass sich insbesondere 'Wasser' anhand seiner Intensität gut von den verbleibenden Klassen unterscheiden lässt. Wie Abbildung 4.8 zeigt, nehmen die \bar{C}_T^2 -Mittelwerte von 'Wasser'/'Offenland' über 'Wald' bis zu 'Siedlungsraum' zu.

Aus dieser Konstellation ergeben sich für ein schwellwertbasiertes Klassifikationsverfahren drei Klassenpaare: 'Wasser' zu 'Offenland', 'Offenland' zu 'Wald' und 'Wald' zu 'Siedlungsraum'. Auf Basis der beiden Merkmale (Intensität und \bar{C}_T^2) kann die Trennung der drei Klassenpaare anhand von sechs Schwellwerten vorgenommen werden. Aufgrund der guten Trennbarkeit von 'Wasser' gegenüber 'Offenland' auf Basis der Intensität sowie von 'Siedlungsraum' und 'Wald' auf Basis der Textur wird für die Unterscheidung dieser Klassen lediglich ein Schwellwert verwendet. Somit basiert das hier vorgestellte Klassifikationsverfahren auf vier Schwellwerten.

Zur Bestimmung der Schwellwerte werden für die jeweils betrachteten Landbedeckungspaare die kumulierten Histogramme in der Art gegenübergestellt, dass der Schnittpunkt des kumulierten Histogramms des Landbedeckungstyps A (z.B. 'Wald') mit dem von eins abgezogenen kumulierten Histogramm des Landbedeckungstyps B (z.B. 'Offenland') ermittelt wird. Der auf die Abszisse abgetragene ermittelte Schnittpunkt bildet im Folgenden den Schwellwert zur Trennung dieser Klassen (Abbildung 4.9).

Die vier gefundenen Schwellwerte werden nachfolgend mit den zu trennenden Klassen und dem verwendeten Merkmal im *Suffix* bezeichnet. So benennt der Schwellwert T_{Ut} den Schnittpunkt und somit die Trennlinie zwischen 'Siedlungsraum' und 'Wald' (U) im \bar{C}_T^2 -Histogramm (t). Dementsprechend bezeichnen die Schwellwerte T_{Wt} und

T_{Wi} die Schnittpunkte zwischen 'Wald' und 'Offenland' (W) im \bar{C}_T^2 -Histogramm bzw. Intensitäts-Histogramm (i). Mit T_{Oi} ist der Schnittpunkt im Intensitäts-Histogramm zwischen 'Offenland' und 'Wasser' (O) gelistet.




Abbildung 4.9: Verfahren zur Ermittlung der Schwellenwerte im Zuge der Klassifikation von Basislandbedeckungstypen. Die gestrichelte Linie zeigt das kumulierte Intensitäts-Histogramm der Klasse 'Offenland'. Das von eins abgezogene kumulierte Histogramm der Klasse 'Wald' ist gepunktet dargestellt. Der auf die Abszisse abgetragene Schnittpunkt beider Linien ergibt den Schwellenwert zur Trennung dieser Klassen.

Zur Klassifikation der *TSX-Stripmap* Daten wird ein hierarchisches Verfahren angewandt, bei dem in einem ersten Schritt, in Abhängigkeit von der Textur, 'Urbane Räume' (UR) klassifiziert werden, da sich diese, wie zuvor gezeigt, auf Basis der Textur sehr gut von den anderen Klassen trennen lassen. Alle Bildelemente p des Testgebietes s , deren \bar{C}_T^2 -Werte größer als T_{Ut} ist, werden der Klasse UR zugewiesen:

$$(\bar{C}_T^2)_p > T_{Ut} \Rightarrow p_s \in UR. \quad (4.17)$$

Anschließend werden die verbleibenden Bildelemente p_r in Abhängigkeit von sowohl Textur als auch Intensität auf Zugehörigkeit zur Klasse 'Wald' (WO) hin geprüft. Dazu müssen nach den Abbildungen 4.7 und 4.8 sowohl der Grauwert der Intensität (I) als auch der Wert der Textur \bar{C}_T^2 jeweils höher sein als die entsprechenden

Schwellwerte T_{Wi} oder T_{Wt} .

$$(I_p > T_{Wi}) \wedge ((\bar{C}_T^2)_p > T_{Wt}) \Rightarrow p_r \in WO \quad (4.18)$$

Nach diesem Schritt sind alle Bildelemente mit hoher und mittlerer Textur klassifiziert. Diejenigen Bildelemente p_h , die, da sie verhältnismäßig ebenes Gelände abbilden, eine geringe Textur besitzen, werden im letzten Schritt in Abhängigkeit von ihrer Intensität (vgl. Abb. 4.7) den Klassen 'Offenland' und 'Wasser' zugeteilt. Alle Bildelemente mit einer Intensität größer T_{Oi} fallen dabei in die Klasse 'Offenland' (OF). Niedrigere Intensitätswerte identifizieren ein Bildelement als 'Wasser' (WA), wie das Histogramm (Abb. 4.7) zeigt:

$$I_p > T_{Oi} \begin{cases} 1 : p_h \in OF \\ 0 : p_h \in WA \end{cases} \quad (4.19)$$

Nachbearbeitung Wie aus Abbildung 4.9 hervorgeht, kann aufgrund der vorhandenen Überschneidungsbereiche der jeweiligen Histogrammpaare keine eindeutige Klassentrennung über die ermittelten Schwellwerte erreicht werden. Diesem Umstand wird in einem Nachverarbeitungsschritt in der Art Rechnung getragen, dass, anschließend an die initiale Klassifikation, ein *Majorityfilter* auf das Klassifikationsergebnis angewandt wird. Dieser Filter weist in einem *Moving-Window*-Verfahren jedes zentrale Bildelement p_z derjenigen Klasse C_{maj} zu, die in einem Umgebungsfenster von 47x47 Pixel am häufigsten vorkommt. Auf diese Weise können kleinräumige, auf Fehlinterpretationen zurückzuführende Ausreißer weitestgehend eliminiert werden.

$$p_z \in C_{maj}; \quad \text{mit : } C_{maj} = \max(\#UR, \#WO, \#OF, \#WA)_{47 \times 47} \quad (4.20)$$

4.4 Analyse von Baugebieten

Nachdem bisher neue Methoden vorgestellt wurden, anhand derer bebaute Areale und vier Basisklassen in einfach polarisierten monotemporalen TerraSAR-X Daten identifiziert werden können, widmen sich die Entwicklungen in diesem Abschnitt verstärkt

dem urbanen Raum. Die vorzustellende Methodik fokussiert auf den Möglichkeiten der Erfassung und Klassifikation von schnell sich wandelnden Räumen, an dieser Stelle ausschließlich Baustellen. Als Untersuchungsräume dienen Baustellen innerhalb des Stadtgebietes von München.



Abbildung 4.10: Beispielhaft für die Kleingliedrigkeit von Baustellen wird hier das Untersuchungsgebiet *Bernhard-Wicki-Straße* gezeigt. Zu sehen sind, neben den gegossenen Betonwänden, Gerätschaften und Baumaterialien.

Ein aus Sicht der Radarfernerkundung entscheidendes Merkmal von Baustellen ist der hohe Grad von Unordnung auf sehr kleinem Raum. Frei stehende Geräte, Baumaterialien und Säulen stellen eine Vielzahl von Reflektoren mit, je nach Orientierung und Material, unterschiedlicher Stärke dar. Selbst für den an sich bereits sehr heterogenen städtischen Raum stellen Baustellen eine Besonderheit bezüglich ihrer Kleingliedrigkeit dar. Abbildung 4.10 zeigt am Beispiel der Baustelle 'Bernhard-Wicki-Straße' die hohe, kleingliedrige Heterogenität des Untersuchungsareals. Beispiele für das Streuverhalten von Radarstrahlung zeigt Abbildung 4.11. Diese hohe Heterogenität kann aufgrund der Berechnungsmethode über Mittelwert und Standardabweichung über Texturmaße basierend auf C_w nur unzureichend dargestellt werden. Um die auf Baustellen vorzufindende Kleingliedrigkeit qualitativ ansprechend beschreiben zu

können, werden für diese Arbeiten zum Einen die GLCM-Texturmaße nach Haralick (1979) verwendet. Zum Anderen basiert die Methode zur Erfassung von Baustellen auf den höchst aufgelösten TSX Datensätzen, den *Spotlight*-HR Daten. Dieser Modus ist besser als die schlechter aufgelösten Modi in der Lage, Details abzubilden.

Ein weiteres wichtiges Merkmal von Baustellen ist die Veränderung der Oberflächenstruktur und damit auch der Rückstreu-Charakteristik in kurzen Zeitintervallen. Diese Veränderungen können mit hoher Genauigkeit anhand einer Veränderungsanalyse nach Schmitt et al. (2010), basierend auf einer *Curvelet-Change-Detection* Methodik (siehe Abschnitt 2.2.3), erfasst werden.




Abbildung 4.11: Streuverhalten von Radarstrahlen am Beispiel der Baustelle 14 ('Arnulfstraße MB Parkplatz').

Müssen für die Veränderungsanalysen jeweils mindestens zwei Datensätze unterschiedlicher Aufnahmetermine verwendet werden, so folgen die anschließenden Untersuchungen zur Erfassung von Baustellen auf monotemporalen Daten. Diese Vorgehensweise trägt dem Umstand Rechnung, dass Baugebiete in der Regel nur über einen relativ kurzen Zeitraum aktiv sind. In dieser kurzen Zeitspanne zwei oder mehr Aufnahmen zu erhalten, ist in der Regel aus Kostengründen nicht im Sinne des Planers. Liegen die Aufnahmezeitpunkte jedoch zu weit auseinander, ist zu erwarten, dass nur sehr selten Baugebiete erfasst werden, die zu beiden Terminen schon bzw. noch

in der Bauphase sind. Zudem wird damit dem bisherigen grundsätzlichen Vorgehen entsprochen und ein erster Schritt getan zur Klassifikation ohne Veränderungsanalyse. Es wird getestet, ob und in welchem Maße sich Baustellen anhand einfacher Schwellwertverfahren in höchst aufgelösten SAR erfassen lassen.

Vorverarbeitung Die Vorverarbeitung der Daten verläuft in zwei Schritten. Zunächst werden anhand zweier aufeinander folgender Szenen Veränderungsanalysen nach Schmitt et al. (2010) durchgeführt. Die auf diese Weise gefundenen Flächen mit Veränderung werden im weiteren Verlauf der Untersuchungen als einzelne Objekte verstanden, auf denen die Analysen durchgeführt werden. Zudem werden auf allen TSX-Szenen die GLCM-Texturmaße sowie die reale Textur \bar{C}_T^2 nach Esch et al. (2011), basierend auf Ulaby et al. (1986a), in einem pixelbasierten *moving-window*-Ansatz ermittelt (vgl. die Ausführungen in Abschnitt 2.2.4 und 2.2.4). Die abgeleiteten Texturen liegen schließlich als eigenständige Daten-Layer vor.

Merkmalsanalyse Der erste Schritt ist die Auswahl der für die Klassentrennung am besten geeigneten Merkmale. **Grundannahme dieser Untersuchungen ist, dass Baustellen in SAR-Daten eine hohe kleinräumige Textur zeigen, die sich von der Textur anderer sich verändernder städtischer Objekte unterscheidet.**

Von den 14 GLCM-Texturen, die Haralick (1979) beschreibt, finden Gu et al. (2008) acht Maße (CON, HOM, DIS, ENT, ASM, MEAN und COR) mit der häufigsten Verwendung in Klassifikationsprozessen. Baraldi und Parmiggiani (1995) beschreiben, dass ASM und ENT eine hohe negative Korrelation aufweisen. Zudem zeigten eigene Untersuchungen, dass VAR und CON einen relativ hohen Korrelationskoeffizienten von 0,95 besitzen. Aus diesem Grund wurden sowohl ASM und VAR bei den weiteren Analysen nicht berücksichtigt. Diese Vorgehensweise wird durch Maillard (2003) bestätigt, der in seinen Untersuchungen hohe Korrelationen zwischen nicht näher genannten GLCM-Texturen findet. Zuletzt wird auch der GLCM-MEAN aus den weiteren Analysen ausgeschlossen, da diese Textur innerhalb des präferierten Softwareproduktes falsch berechnet wird. Somit konzentrieren sich die weiteren Analysen auf die fünf Maße CON, HOM, DIS, ENT und COR.

Im nächsten Schritt werden für die fünf ausgewählten GLCM-Texturmaße auf jedem Veränderungsobjekt die statistischen Maße Mittelwert (mean), Minimum (min), Maximum (max), Standardabweichung (stbw) und Median (med) berechnet. Für jedes GLCM-Maß werden demnach fünf Merkmale auf ihre Eignung zur Trennung von Baustellen gegenüber anderen Flächen mit Veränderung untersucht. Die Eignung der Merkmale wird anhand der von Breiman und Cutler (2004) oder Strobl (2008) vorgestellten Parameter *Mean Decrease in Accuracy* (MDA) und *Mean Decrease Gini* (MDG) überprüft und bewertet.

Beide Maße werden im Zuge von sogenannten *Random Forest*-Klassifikatoren (Breiman 1996, 2001) ermittelt und geben jeweils einen Kennwert für die Relevanz der untersuchten Merkmale zur Trennung der verwendeten Klassen. Dabei beziffert MDA die Abnahme der Klassifikationsgenauigkeit, die durch die Nichtbeachtung des jeweiligen Merkmals erlitten wird (Strobl et al. 2007). Innerhalb eines *Random Forest*-Klassifikators bezeichnet MDG die Abnahme der Unreinheit einer Stichprobe nach jedem Entscheidungsknoten innerhalb eines Klassifikationsbaumes (Breiman und Cutler 2004). Nähere Informationen zu *Random Forest*-Klassifikatoren und Entscheidungsbäumen sind der zitierten Literatur zu entnehmen.

Die Bewertung der Relevanz von Merkmalen auf Basis dieser beiden Parameter wird unter der Prämisse vorgenommen, dass eine hohe Relevanz innerhalb der Klassifikationsbäume auch eine hohe Relevanz bei Verwendung eines einfachen Schwellwertverfahrens bedeutet. Diese Annahme stützt sich auf die Tatsache, dass Klassifikationsbäume im Grunde auf einer Kombination mehrerer nacheinander geschalteter Schwellwertentscheidungen basieren. Ziel der Merkmalsanalyse ist, die drei GLCM-Merkmale mit dem größten Einfluss auf die Klassifikationsgüte zu ermitteln. Mit der Beschränkung auf drei Merkmale soll der Aufwand in der Vorverarbeitung der Daten minimiert werden.

Klassifikation Die drei Merkmale, die in der Merkmalsanalyse die beste Eignung zur Trennung von Baustellen gegenüber andere Veränderungsflächen zeigen, werden im Weiteren zur schwellwertbasierten Klassifikation verwendet. Für jedes der verwendeten Merkmale wird der niedrigste Wert, der auf der Fläche einer Referenz-Baustelle




Abbildung 4.12: Schematische Darstellung der Methodik zur objektorientierten Klassifikation von Baustellen innerhalb des Untersuchungsgebietes München.

gefunden werden kann, als Schwellwert für die Klassifikation herangezogen. Die Verknüpfung der drei Schwellwerte wird dabei über eine logische Oder-Verknüpfung vorgenommen. Überschreitet ein Objekt den entsprechenden Schwellwert eines der Merkmale, wird dieses Objekt der Klasse 'Baustelle' zugewiesen. Eine schematische Darstellung des Ablaufs der Methodik wird in Abbildung 4.12 gezeigt.

4.5 Validierung der Ergebnisse

Bewertung Zur Methodenvvalidierung wird in dieser Arbeit auf die von Congalton (1991) beschriebene Methodik zurückgegriffen. Dabei werden zufallsbasiert 1500 über die jeweilige Szene verstreute Bildelemente ausgewählt und auf ihre Klassenzugehörigkeit getestet. Diese Bildelemente stellen die Referenz dar, mit der das Klassifikationsergebnis in einer sogenannten Fehlermatrix verglichen wird. Aus dieser Matrix können verschiedene Kennzahlen berechnet werden, die Aussagen über die Qualität einer vorliegenden Bildklassifikation erlauben. Die wichtigsten und in dieser Arbeit

verwendeten Kennzahlen sind

- die Gesamtgenauigkeit: Stellt die Anzahl der richtig klassifizierten Bildelemente zu der Gesamtzahl der Referenzpunkte in Beziehung. Gibt also den prozentualen Anteil der insgesamt richtig klassifizierten Bildelemente wieder.
- die Nutzergenauigkeit: Stellt die für jede Klasse richtig klassifizierten Bildelemente der Anzahl der insgesamt dieser Klasse zugewiesenen Bildelemente gegenüber.
- die Erzeugergenauigkeit: Beschreibt den Anteil der richtig klassifizierten Bildelemente einer jeden Klasse im Verhältnis zur Referenz.
- der Kappa-Wert: Ist ein Maß um die Verbesserung einer Klassifikation gegenüber einer rein zufällig getroffenen Klassifikationsentscheidung zu beziffern.

Näheres zum verwendeten Verfahren und den Kennzahlen ist den Arbeiten von Congalton (1991), Richards und Jia (1999) sowie Albers (2001) zu entnehmen.

Da im Zuge der objektorientierten Klassifikation von bebauten Arealen an die Segmentierungsebenen $L1$ und $L0$ nicht der Anspruch erhoben wird, reale Objekte abzubilden, wurde auf die Anwendung eines objektorientierten Verfahrens zur Bewertung der Klassifikationsgüte, wie etwa von Esch et al. (2008b) oder Clinton et al. (2008) vorgeschlagen, verzichtet.

Referenzen Zur Kontrolle der Klassifikationsgenauigkeit dienten die Bilddaten von GoogleEarth® als Referenz. Dabei wurde berücksichtigt, dass das Aufnahmedatum der frei zugänglichen Bilddaten in der Regel erheblich vom Aufnahmedatum der SAR-Daten abweicht. Da urbane Räume jedoch mitunter einem raschen Wandel unterliegen, wird in allen Fällen ein Vergleich der in den SAR-Daten zu erkennenden Strukturen mit denen in GoogleEarth® abgebildeten vorgenommen. In Fällen, in denen erkennbar ist, dass sich die Strukturen zwischenzeitlich verändert haben, wird der entsprechende Punkt in der Genauigkeitsanalyse ausgelassen und gegebenenfalls durch einen neuen, zufallsbasiert ermittelten Referenzpunkt ersetzt. In unterschiedlichen Szenen kann der jeweilige Gesamtanteil der abgebildeten Klassen stark variieren.

Ein Vergleich der klassenbasierten Genauigkeiten zwischen den einzelnen Szenen ist jedoch für die Fehleranalyse wichtig. Daher werden für jede Szene und jede Klasse jeweils die gleiche Anzahl an Referenzpunkten ausgewählt.

5

Ergebnisse und Diskussion

Nachdem im vorhergehenden Kapitel die neu entwickelten Methoden vorgestellt wurden, sollen nun die Ergebnisse ihrer Anwendung vorgestellt und diskutiert werden. Entsprechend dem Methodenteil wird zunächst auf die Ergebnisse der Erfassung von bebauten Arealen inklusive der Übertragbarkeitstests eingegangen. Im Anschluss folgen die Darstellung der Resultate der Landbedeckungsklassifikation (Abschnitt 5.3) und der Möglichkeit zur Erfassung von Baustellen (Abschnitt 5.4).

5.1 Erfassung bebauter Areale mit Hilfe von SAR-Daten

Zur Bewertung der beiden in Abschnitt 4.1 vorgestellten Methoden zur Erfassung von bebauten Arealen aus TSX-*Stripmap*-Daten wurden beide Algorithmen, der objektorientierte sowie der pixelbasierte, auf SM-Szenen von zwölf Testgebieten angewandt. An dieser Stelle werden nun zunächst die Ergebnisse des objektorientierten Ansatzes, danach die des pixelbasierten Verfahrens vorgestellt und, daran anschließend, beide Methoden miteinander verglichen.

5.1.1 Objektorientierter Ansatz

Klassifikationsgüte Für alle 12 Testgebiete konnte auf Basis des globalen Parametersatzes (vgl. Tab. 4.3 in Abschnitt 4.1) eine Maske des bebauten Areals erzeugt werden. Dabei zeigten alle Masken, bis auf jene für das Testgebiet Lagos (LOS), gute Gesamtgenauigkeiten, was durch Kappa-Werte größer 0,6 belegt wird. Die höchste Güte wird mit annähernd 96% für das Testgebiet Istanbul (IST) erzielt, während für Padang (PDG) mit 86,4% die geringste Güte — neben LOS (76,1%) — erreicht wird.

Im Hinblick auf die Art der Fehler zeigt sich meist eine Überschätzung des bebauten Areals, dies belegen die höheren Werte der Herstellergenauigkeit (HG) gegenüber der Nutzergenauigkeit (NG). Die deutlichste Überklassifizierung weist LOS auf ($NG = 67,4\%$; $HG = 95,3\%$). Technisch betrachtet, finden sich dort weite Bereiche mit hohen Intensitätswerten und/oder hoher Textur auf kleinem Raum, welche jedoch nicht bebautes Areal abbilden. Diese Bereiche zeigen die Doppelreflexionen von im Wasser stehenden Bäumen, Sumpfgebiete am Rand der Lagune von Lagos, Boote sowie Bojen auf der Lagune bzw. starke Rückstreuer, die durch freistehende Bäume oder Felsen innerhalb des angrenzenden Waldgebietes entstehen. Diese Flächen werden somit aufgrund ihres Rückstreuerverhaltens häufig als bebautes Areal fehlgedeutet.

Für die Testgebiete BUE, MEX, NBO und SYD findet sich eine Umkehrung der Verhältnisse, hin zur Unterklassifizierung. Dort kann mit höherer Wahrscheinlichkeit davon ausgegangen werden, dass Bereiche, die als bebautes Areal klassifiziert wurden auch solches abbilden. Größere Teile des Zielareals konnten nicht identifiziert werden, vor allem im Testgebiet NBO, hier wird eine Herstellergenauigkeit von 81,6% erreicht. Die Ursache für die schlechte Herstellergenauigkeit liegt in der hügeligen Region im Nordwesten des Stadtgebietes: Dort befinden sich viele einzelstehende Gebäude, deren Rückstreusignale sowohl von der Abschattung durch Bäume als auch vom Relief beeinflusst werden. Intensität und Textur sind in diesen Bildbereichen niedrig, es werden wenige DBC identifiziert, das *region growing* wird zudem abgeschwächt.

Die Gesamtgenauigkeit der vier Testgebiete, die in weniger entwickelten Regionen liegen — HYD, LOS, NBO und PDG —, fallen mit jeweils unter 90% geringer aus als die aller anderen Testgebiet. Mit Ausnahme von NBO kann in diesen Testgebiete-

Tabelle 5.1: Ergebnisse der Genauigkeitsanalyse der objektorientierten Erfassung bebauter Areale mit TerraSAR-X *Stripmap* Daten.

Testgebiet	Gesamt- genauigkeit [%]	Kappa	Hersteller	Nutzer
BUE	94,8	0,896	94,4	95,2
CTU	90,8	0,816	93,4	89,2
HYD	87,6	0,753	93,6	82,3
IST	95,8	0,916	98,3	93,2
LOS	76,1	0,530	95,3	67,4
MEX	93,0	0,864	90,7	96,1
MUC	94,8	0,884	97,3	87,7
NBO	88,0	0,757	81,6	91,9
PDG	86,4	0,730	96,2	77,1
PHX	93,2	0,864	93,6	92,8
SYD	94,6	0,892	92,4	97,2
THR	91,4	0,828	96,4	87,8
Gesamt	90,6	0,810	93,5	87,5

ten zudem eine ausgeprägte Neigung zur Überklassifizierung festgestellt werden. Die schlechteren Klassifikationsergebnisse auf diesen Gebieten sind auf die weitestgehend ungeplant vorgenommene Bebauung zurückzuführen, die Trennung von Stadtgebiet zu Umland ist schwächer ausgeprägt. Damit einher geht eine geringere Strukturiertheit, die häufig in einer weitläufigeren Verteilung von Gebäuden mündet. Im Bild führt dies zu einer breiten Streuung von *DBC*, in deren Umfeld Freiflächen als bebautes Areal fehlinterpretiert werden.

Die Klassifikationsergebnisse der zwölf Testgebiete sind in Tabelle 5.1 aufgeführt. Die letzte Zeile dieser Tabelle zeigt die aufsummierten Ergebnisse der Genauigkeitsanalysen. Diese Zusammenfassung liefert eine Gesamtgenauigkeit von 90,6% über alle Szenen. Die Hersteller- und Nutzergenauigkeit, die sich aus dieser Betrachtung ergeben, liegen in einem engen Bereich bei 93,5% bzw. 87,5%, ein Beleg für die Robustheit des Verfahrens.

Abbildung 5.1 zeigt, beispielhaft, anhand der Testgebiete PDG, Buenos Aires (BUE), Mexiko City (MEX), LOS, IST und München (MUC) das Produkt der ob-

jektorientierten Methode zur Erfassung von bebauten Arealen.

Um das Potential der Methode näher untersuchen zu können, wurden für jene Testgebiete mit geringerer Klassifikationsgüte (unter 93%) jeweils individuelle Parametersätze (vgl. Tab. 4.3) zur Klassifikation entwickelt. Die Anwendung des individuellen Parametersatzes verbessert insbesondere die Klassifikationsgüten der Testgebiete Hyderabad (HYD) mit einer neuen Gesamtgenauigkeit von 95,7%, LOS (87.8%) und PDG (91,2%). Für Chengdu (CTU), Nairobi (NBO) und Teheran (THR) können geringe Verbesserungen, im Falle von NBO keine Steigerung der Genauigkeit erreicht werden (vgl. Tab. 5.2). Insgesamt gesehen, kann die Anwendung individueller Parametersätze eine Steigerung der Klassifikationsgüte gerade in schlechter entwickelten Regionen bewirken. Die zuvor beschriebenen Fehlinterpretationen können auf einigen Testgebieten deutlich reduziert werden, ohne jedoch zufriedenstellende Ergebnisse für alle Testgebiete erzielen zu können. So liegt die Gesamtgenauigkeit für LOS noch immer unter 90%, was vorwiegend auf die bereits oben beschriebenen Schwierigkeiten im Zusammenhang mit der Lagune von Lagos zurückzuführen ist.

Das Ausbleiben einer Verbesserung der Klassifikationsgüte für NBO liegt in den störenden Einflüssen der Topographie in den nordwestlichen Ausläufern der Stadt begründet (vgl. Abb. 2.4, sowie die Erläuterungen zu Verkürzung, Überlagerung und Schatten in den Radargrundlagen). Ein weiterer Faktor ist, dass auf diesen Flächen eine Vielzahl frei stehender Bäume und kleinerer Wälder in der SAR-Aufnahme eine hohe Textur verursachen, wie sie für die Klasse *UA* typisch ist. In Verbindung mit den vorhandenen Gebäuden, die richtig als *DBC* identifiziert werden, führt dies zu einem Anwachsen des bebauten Areals in diesen Bereichen und somit zu verstärkter Überklassifikation. Tabelle 5.2 zeigt die Klassifikationsgenauigkeiten der Testgebiete, für die ein individueller Parametersatz zur Klassifikation erstellt wurde. Dort ist auch die erreichte Differenz zur Gesamtgenauigkeit auf Basis des globalen Parametersatzes gelistet.

Detailanalyse Die vorgestellte Methode ermöglicht die Trennung von bebautem Areal von unbebauten Flächen auf Basis von TerraSAR-X *Stripmap* Daten mit hoher Genauigkeit. Besonders gut erfasst werden große zusammenhängende Bereiche.




Abbildung 5.1: Ergebnisse der objektorientierten Erfassung bebauter Areale (rote Flächen). Dargestellt sind die TerraSAR-X Stripmap Szenen (a) der Testgebiete Padang (1), Buenos Aires (2), Mexiko City (3), Lagos (4), Istanbul (5) sowie München (6) und die für diese Gebiete abgeleiteten Flächen bebauten Areals (b).

Tabelle 5.2: Klassifikationsgüten des objektorientierten Ansatzes, die auf Basis der Anwendung individueller Parametersätze erzielt wurden. Die Veränderung bezeichnet die Abweichung zur Gesamtgenauigkeit basierend auf dem globalen Parametersatz.

Testgebiet	Gesamt [%]	Veränderung	Kappa	Hersteller [%]	Nutzer [%]
CTU	92,4	1,6	0,848	91,4	93,6
HYD	95,7	8,1	0,912	96,5	93,2
LOS	87,8	11,7	0,756	89,4	85,4
NBO	88,0	0,0	0,757	81,6	91,9
PDG	91,2	4,8	0,824	99,1	83,2
THR	94,2	2,8	0,884	93,7	94,8
Gesamt	93,0	-	0,859	92,9	92,1

Einzelne stehende Gebäude können in den gut entwickelten Regionen Europas und Asiens meist identifiziert werden (vgl. Abb. 5.2 2a-d). Die Stärken der Verwendung von Texturmaßen zur Klassifikation zeigen sich deutlich — erlauben sie doch eine Erfassung von bebautem Areal häufig auch in solchen Bildbereichen, in denen strukturelle Unterschiede in der Intensitätsszene nur schwer zu erkennen sind (vgl. Abb. 5.2 3a-d).

Bei einer näheren Betrachtung der Fehlklassifikationen auf Basis des globalen Parametersatzes lassen sich fünf Hauptfehlerquellen identifizieren. Zunächst der Blick auf die *error of omission* (Flächen, die zwar bebautes Areal abbilden, jedoch nicht als solche erkannt werden): Etwa zwei Drittel dieser Fehler beruhen auf relativ großen, ebenen Flächen mit geringem Rückstreuquerschnitt. In der Realität sind solche Flächen in der Regel Parkplätze oder auch Flachdächer großer Gebäude, wie z.B. Fabrikhallen. Diese Flächen besitzen eine sehr niedrige Intensität und eine geringe Textur. Aufgrund dieser sehr niedrigen Werte ist der Algorithmus nicht in der Lage, diese Objekte im Verlauf des *region growings* zu fassen (vgl. Abb. 5.2 1a-1d). Sie ähneln in ihrem Erscheinungsbild in SAR-Szenen kleinen Wasserobjekten. Über die Einbindung von Nachbarschaftsbeziehungen kann diese Fehlerquelle nur unzureichend behoben werden, da vermehrt Wasserflächen in die erstellte Maske einfließen würden. Dies wirkt sich stärker negativ auf das Gesamtergebnis aus als die positiven Effekte durch die Korrektur dieser Fehler.

Eine weitere häufige Fehlerquelle der Unterklassifizierung tritt in Bereichen kleinerer Gehöfte auf. Diese sind meist von Bäumen umstanden, der Radarrückstreuquerschnitt ist daher gering und führt zu niedriger Intensität und geringer Textur. Solche Gehöfte können nicht als *DBC* klassifiziert werden. Über das *region growing* könnten diese Objekte auf Grund ihrer Textur als *PUS* oder *UA* angesprochen werden, allerdings nur unter der Voraussetzung, dass genügend *DBC* im näheren Umfeld klassifiziert wurden. Die Teilabbildungen 5.2 2a-2d zeigen die Klassifikation kleiner Gehöfte im Testgebiet MUC.

Eine Untersuchung der fehlerhaft als bebautes Areal klassifizierten Flächen, dem *error of commission* (EOC), ergab folgende Hauptfehlerquellen: Etwa zwei Drittel dieser Fehler sind darauf zurückzuführen, dass durch die fensterbasierte Berechnung der Textur um den eigentlichen Siedlungskörper herum ein schmaler Saum mit vergleichsweise hoher Textur erzeugt wird, der als bebautes Areal klassifiziert wird. Für etwa 13% der EOC sind Objekte verantwortlich, für die, wie starke urbane Rückstreuungszentren auch, eine hohe Intensität charakteristisch sind. Solche Objekte finden sich insbesondere in hügeligen oder gebirgigen Regionen. Hangverkürzung und Überlagerungseffekte lassen dem Sensor zugewandte Hänge als sehr helle Flächen erscheinen (vgl. Abschnitt 2.1.1). In Verbindung mit den dunkleren Flächen auf der dem Sensor abgewandten Seite der Hügel/Berge ergibt sich im Bereich des Bergkamms eine hohe Textur. Somit finden sich in diesen Bereichen alle Eigenschaften, die nach der hier vorgestellten Methode bebautes Areal kennzeichnen. Dies verdeutlicht die Schwächen der Verwendung von \bar{C}_T^2 gegenüber anderen Texturmaßen, wie z.B. die GLCM-Maße (vgl. Abschnitt 2.2.4), die unterschiedliche Grauwertanordnungen bewerten können (vgl. Abb. 2.13). Weitere etwa 12% der EOC werden durch Areale verursacht, die im direkten Umfeld von Bebauungen liegen und auf Grund ihrer Oberflächenstruktur \bar{C}_T^2 -Werte aufweisen, die denen von UA ähnlich sind. Solche Rückstreuungen werden durch aufgerauten offenen Boden oder lichte Wälder, sofern Teile ihres Festholzes nicht von Blattmasse verdeckt sind, verursacht.

Abbildung 5.2 zeigt Schwächen und Stärken dieser Methodik beispielhaft auf drei kleinen Arealen. In der linken Spalte (1a-1d) werden auf einem Ausschnitt des Stadtgebietes von PHX die oben angesprochenen Probleme mit größeren innerstädtischer Flächen mit geringem Radarrückstreuquerschnitt dargestellt. Die mittlere Spalte (2a-

2d) zeigt auf einem Ausschnitt der Stadt-Umlandregion München, dass kleinere Gehöfte von dieser Methodik erfasst werden können. Zu sehen ist jedoch auch, dass Gehöfte, die in Richtung zum Sensor von Bäumen verdeckt sind, nicht richtig erfasst werden. Die rechte Spalte (3a-3d) zeigt einen Ausschnitt im Norden von Teheran, gelegen in der Nähe der *Allameh Tabatabaei Universität*. Die Radar-Intensität (3a) zeigt kaum zu erkennende Unterschiede in der Struktur: Das Stadtgebiet im Osten sowie die Waldflächen im Westen sind sich sehr ähnlich. Der \bar{C}_T^2 -Layer (3b) hingegen zeigt deutlich erkennbare Unterschiede zwischen dem östlichen und dem westlichen Teil des Ausschnittes und ermöglicht so eine recht gute Abgrenzung der bebauten Areale von ihrem Umland (3c).

5.1.2 Pixelbasierter Ansatz

Insgesamt gesehen, liegen die Gesamtgenauigkeiten bei der Anwendung des pixelbasierten Ansatzes zur Erfassung bebauter Areale geringfügig unter denen des objektorientierten Verfahrens. Im Einzelnen werden mit dem pixelbasierten Ansatz Genauigkeiten zwischen knapp 95% bei einem Kappa von 0,896 für THR und etwa 64% (Kappa: 0,313) für HYD erreicht. Das Ergebnis des Testgebietes HYD weicht dabei stark von dem der anderen Testgebiete, deren Genauigkeiten deutlich oberhalb von 80% liegen, ab (vgl. Tab. 5.3). Der pixelbasierte Ansatz zeigt eine Tendenz zur Überklassifizierung, die sich insbesondere in den Testgebieten CTU, HYD, MEX, MUC sowie PDG abzeichnet. Im pixelbasierten Verfahren wird sie in erster Linie durch die großzügige Interpretation von Siedlungsrandlagen als bebautes Areal verursacht. Weiterhin sind häufig EOC im Kontext von Uferbereichen zu finden. Diese besitzen aufgrund des Übergangs von dunklen (Wasser) zu helleren (Land) Bildbereichen eine hohe Textur.

Die Testgebiete NBO, PHX und SYD weisen eine sehr stark ausgeprägte Unterklassifizierung (Differenz Hersteller ./ Nutzer größer als 10%) auf. Diese ist in allen drei Testgebieten auf Areale zurückzuführen, in denen nicht genügend DBC gefunden werden. In NBO ist ein solches Areal im Osten der Stadt zu finden. Hier stehen viele kleine einzelne Gebäude, die von Bäumen und Sträuchern umgeben sind, durch die der *double-bounce* verhindert wird. In PHX und SYD führt die Abwesenheit von DBC




Abbildung 5.2: Diskussion der objektorientierten Erfassung bebauter Areale. Die Teilabbildungen 1a bis 1d zeigen einen Ausschnitt der Stadt Phoenix. Im Nordosten und im Südwesten dieses Ausschnittes sind große Industriegebäude mit Flachdächern zu sehen, die durch die Methodik nicht erfasst werden können. 2a bis 2d zeigen einen Ausschnitt der Stadt-Umlandregion München. Kleine Gehöfte können häufig nicht erfasst werden, wenn sie in Richtung Sensor von Bäumen verdeckt sind. 3a bis 3d zeigt, am Beispiel eines Ausschnittes aus dem Norden von Teheran, die gute Trennung bebauter Areale von Waldflächen unter Einbindung der verwendeten Textur innerhalb des Algorithmus. Die Luftbildausschnitte wurden GoogleEarth® entnommen (Quelle: verändert nach Esch et al. (2010)).




Abbildung 5.3: Beispiel einer lückenhaften Erfassung von bebautes Areal auf dem Testgebiet SYD. Teilabbildung a zeigt den Ausschnitt der TerraSAR-X *Stripmap* Szene. In Teilabbildung b wird diesem Ausschnitt in Rot das als bebautes Areal erfasste Gebiet überlagert. In c ist der identische Ausschnitt als Luftbild (GoogleEarth®) zu sehen. Nähere Beschreibungen sind dem Text zu entnehmen.

eher zu einer Vielzahl kleinerer Lücken im erfassten Siedlungskörper. Die Gebäude stehen hier dichter als in NBO und die geringe Anzahl von erkennbaren Kanten sorgt für eine schwache Rückstreuung. Hinzu kommt, dass der Winkel, in dem die Gebäude zum Sensor orientiert sind, die Strahlung vom Sensor wegleitet und nicht zum Sensor hin reflektiert (vgl. Abb. B.3 in Anhang B). Für diese beiden Testgebiete könnte eine Vergrößerung der Ausreißereliminierung zu einer verbesserten Klassifikation führen. Abbildung 5.3 zeigt einen kleinen Ausschnitt aus dem Testgebiet SYD, in dem die lückenhafte Erfassung von Siedlungsräumen dargestellt ist.

Tabelle 5.3 listet die Genauigkeitsmaße aller pixelbasiert erstellten Masken der zwölf Testgebiete auf. Die unterste Zeile zeigt das zusammengefasste Ergebnis aller Testgebiete. Für ein standardisiertes, voll automatisiertes pixelbasiertes Verfahren auf einem weit gestreuten Anwendungsgebiet kann mit einer zusammengefassten Gesamtgenauigkeit von 88,5% ein zufriedenstellendes Ergebnis erzielt werden. Der enge Bereich, in dem sich in der Zusammenfassung die Hersteller- und Nutzergenauigkeit mit 89% bzw. 86% bewegen, deutet auf eine robuste Methodik.

Eine weitere Detailanalyse der Fehler ergab im Wesentlichen die gleichen Feh-

Tabelle 5.3: Klassifikationsgüten der pixelbasierten Erfassung bebauter Areale auf Basis von TerraSAR-X-*Stripmap* Daten.

Testgebiet	Gesamt- genauigkeit [%]	Kappa	Hersteller	Nutzer
BUE	94,2	0,884	95,6	93,1
CTU	88,4	0,767	93,0	85,6
HYD	64,3	0,313	84,3	41,9
IST	94,4	0,888	93,7	94,5
LOS	92,0	0,840	92,0	91,2
MEX	89,0	0,777	95,2	85,9
MUC	93,6	0,856	94,5	86,5
NBO	85,8	0,712	72,2	97,0
PDG	91,6	0,830	94,3	86,8
PHX	82,4	0,647	69,8	93,0
SYD	90,8	0,817	84,8	97,4
THR	94,8	0,896	96,8	93,2
Gesamt	88,5	0,770	89,0	86,3

lerquellen wie im objektorientierten Verfahren. Allerdings konnten zwei zusätzliche Quellen für Fehlinterpretationen identifiziert werden. Diese werden im folgenden Abschnitt im Zuge des Vergleichs der beiden Verfahren näher erörtert.

5.1.3 Vergleich der beiden Verfahren

Nachdem in den vorangegangenen Abschnitten die Ergebnisse der beiden in den Abschnitten 4.1.1 und 4.1.2 vorgestellten Verfahren zur Erfassung bebauter Areale dargestellt wurden, soll nun ein Vergleich dieser beiden Methoden erfolgen, und zwar exemplarisch anhand eines Ausschnittes von HYD. Verglichen werden nur die beiden unüberwachten Ansätze.

Die Klassifikationsgüten der beiden Verfahren (vgl. Tab. 5.1 und 5.3) weichen für die meisten Testgebiete in einem Bereich von $\pm 5\%$ voneinander ab. Lediglich die drei 'Ausreißer' HYD (Unterschied: 23,3%), LOS (15,9%) sowie PHX (10,8%) zeigen weitaus größere Differenzen. Die Gründe hierfür sind in der schlechteren Erfassung




Abbildung 5.4: Vergleich des objektorientierten mit dem pixelbasierten Verfahren zur Erfassung bebauter Areale am Beispiel des *Saroor Nagar* Sees im Südosten des Testgebietes HYD. Teilbild a. zeigt die Radarintensität, b. die Textur dieses Ausschnittes. In Teilbild d. ist zur besseren Veranschaulichung ein Luftbild (GoogleEarth®) dargestellt. In c. sind die Ergebnisse der beiden Klassifikationsmethoden zusammengefasst. NBA bezeichnet dabei die Klasse 'nicht bebautes Areal'; BA die Klasse 'bebautes Areal'. Nähere Beschreibungen siehe Text. (Quelle: verändert nach Esch et al. (2010)).

des bebauten Areals durch jeweils eine der beiden Methoden zu sehen, wie für LOS und PHX bereits dargelegt. Die Ursachen für die großen Unterschiede in der Klassifikationsgüte für HYD werden nachfolgend anhand eines kleinen, südlich an den *Saroor Nagar See* grenzenden Ausschnittes diskutiert (Abb. 5.4).

Dazu wurde, basierend auf den berechneten Masken bebauter Flächen, eine Überlagerung (Abb. 5.4c) beider Verfahren vorgenommen. Abgebildet sind zudem die TSX-*Stripmap*-Intensitätsszene (Abb. 5.4a), die daraus abgeleitete Textur (Abb. 5.4b) sowie eine Luftbildaufnahme (Abb. 5.4d) des gleichen Ausschnittes. Der Vergleich der

beiden Methoden zeigt, dass weite Bereiche dieses Ausschnittes von beiden Verfahren identisch erfasst werden (grün bzw. rot eingefärbt). Dies sind jene Bereiche, die eindeutig als bebautes Areal (rot) oder nicht bebautes Areal (grün) erkannt werden. In Blau sind diejenigen Bereiche dargestellt, die nur von der objektorientierten Methodik als bebautes Areal erfasst werden. Flächen, die nur vom Pixel basierten Verfahren als bebautes Areal klassifiziert werden, sind in Gelb dargestellt. Die an diesem Beispiel aufgezeigten Fehler treten nicht nur im Testgebiet HYD auf.

Randbereiche von Gewässern, die an Siedlungsflächen angrenzen, werden im pixelbasierten Verfahren häufig fehlerhaft als bebautes Areal klassifiziert (so z. B. weite Teile der gelben Flächen in Abb. 5.4b). Dies ist auf den Umstand der ausschließlichen Verwendung der Textur zurückzuführen. Aufgrund ihrer einfachen Berechnung auf Fenstern und der Tatsache, dass Wasserflächen mit geringer Intensität an Siedlungsflächen mit vergleichsweise hoher Intensität angrenzen, ist die Textur in diesen Bereichen hoch genug, um als *UA* klassifiziert zu werden. Im objektorientierten Ansatz werden Fehlklassifikationen durch Einbindung der Intensität als Klassifikationskriterium vermieden. Die geringe Intensität von Wasserflächen dient als Ausschlusskriterium.

Weiträumige innerstädtische Areale mit geringer Textur — in der Regel Parkanlagen und Freiflächen — sowie Bereiche, in denen die Bebauung sehr dicht steht und zudem eine niedrige Höhe aufweist (meist Slums; vgl. die blauen Flächen im Südwesten der Abb. 5.4b), stellen im pixelbasierten Ansatz eine häufige Fehlerquelle dar. Zum Einen, weil bei derartigen Flächen die Textur verhältnismäßig niedrig ist, so dass das Klassifikationskriterium für *UA* nicht erfüllt wird. Zum Anderen sind in diesen Bildbereichen häufig keine starken Rückstreuer vorhanden, so dass keine *DBC* klassifiziert werden. Im objektorientierten Ansatz werden diese Bereiche sowohl über das *region growing* als auch über die Einbindung vollkommen von bebaute Areal umschlossener Flächen erfasst. Im pixelbasierten Ansatz wird versucht, diese Areale mit Hilfe des *seeve and clumb*-Verfahrens nachzubilden. Eine vollständige Abdeckung kann anhand dieses Verfahrens jedoch nicht erzielt werden.

Bewertung Abschließend kann festgehalten werden, dass beide Verfahren gute Ergebnisse zur Erfassung bebauter Areale liefern. Die Gesamtgenauigkeit liegt in dem Bereich, den auch Stasolla und Gamba (2008a) für das Testgebiet Gibraltar — Gesamtgenauigkeit besser 90% bei einem Kappa von 0.7 — erzielen. Werden nur die Testgebiete für den Vergleich herangezogen, die in weiter entwickelten Regionen liegen (BUE, MUC, PHX und SYD), liegen sie mit 94,4% (objekt-orientiert) beziehungsweise 90,3% (pixelbasiert) höher, mit Ausnahme des pixelbasierten Ergebnisses für PHX (vgl. Tab. 5.1 und 5.3). Auf Basis der gleichen Referenzpunkte aller Testgebiete liegt die Genauigkeit der erzeugten Masken im objektorientierten Verfahren um 2,1% höher als im pixelbasierten. Schwankungen in der Klassifikationsgenauigkeit größer als 5% zeigen lediglich drei Untersuchungsgebiete. Dies kann als Beleg für eine gleichwertige Klassifikation gesehen werden. Beide Verfahren sind unüberwacht und automatisiert anwendbar. Der Vorteil des pixelbasierten Verfahrens ist, dass hier alle Arbeitsschritte, vom Intensitätsbild bis zur fertigen Klassifikation, in einem Softwarepaket umgesetzt werden können. Der objektorientierte Ansatz erfordert eine Kombination verschiedener Softwarepakete.

5.2 Übertragung der Methodik

Im Folgenden werden die Ergebnisse der Tests zur Übertragbarkeit der **pixelbasierten Methode** zur Erfassung bebauter Areale vorgestellt und diskutiert. Zunächst werden weitere Ergebnisse im Sinne der räumlichen Übertragung vorgestellt, um dann auf die Übertragbarkeit in der Zeit einzugehen. Daraufhin folgt die Vorstellung der Tests zur Übertragung auf unterschiedliche Skalen. Dabei wird die Methodik auf Daten der beiden anderen TSX-Aufnahmemodi (*Spotlight* und *ScanSAR*) angewandt. Zum Abschluss folgt, mit der Anwendung der Methodik auf ALOS-PALSAR-Daten, die Übertragung auf eine andere Radarfrequenz.

5.2.1 Räumliche Übertragung

In Abschnitt 5.1.2 wurden die Ergebnisse der Klassifikation von zwölf Testgebieten vorgestellt. An dieser Stelle werden nun drei weitere Ergebnisse besprochen und dabei insbesondere die Möglichkeit zur räumlichen Übertragung bewertet.

Validierung Neben den in Tabelle 5.3 aufgeführten Ergebnissen wurden im Zuge der Tests der räumlichen Methodenübertragung mit Mumbai (MUM), Paris (PAR) und Potsdam-Berlin (PBE) drei weitere Testgebiete untersucht. Tabelle 5.3 listet die Genauigkeitsmaße der Siedlungsmasken dieser drei Untersuchungsgebiete. Wie zuvor, können auch für diese Testgebiete Masken mit guter Qualität erstellt werden, alle Kappa-Werte liegen über 0.6. Auffallend ist zudem, dass hier die schlechteste Gesamtgenauigkeit für MUM (86,9%) erzielt wird. Auf den mitteleuropäischen Testgebieten PBE (94,0%) und PAR (92,5%) kann die Siedlungsmaske mit deutlich höherer Güte erstellt werden.

Tabelle 5.4: Weitere Ergebnisse der pixelbasierten Erfassung bebauter Areale auf Basis von TerraSAR-X *Stripmap* Daten.

Testgebiet	Gesamtgenauigkeit [%]	Kappa	Hersteller [%]	Nutzer [%]
MUM	86,9	0,690	79,6	84,3
PAR	92,5	0,845	95,9	86,1
PBE	94,0	0,878	97,1	89,4

Bewertung Die hohe Güte der vorgestellten Siedlungsmasken (vgl. Tab. 5.3 und 5.4) ist ein Indikator für die gute räumliche Übertragbarkeit der hier vorgestellten Methode. Verschiedene urban geprägte Räume wurden untersucht. Die zuvor dargestellte Fehleranalyse zeigt zudem, dass die Hauptursachen für Fehlinterpretationen nicht auf unterschiedliche Stadttypen zurückzuführen sind, sondern vielmehr technisch bedingt bzw. in dem Rückstreuverhalten unterschiedlicher Stadtstrukturen zu suchen sind. Hierin ist im Hinblick auf die Methodenübertragung im Raum der limitierende Faktor zu sehen. Im Bezug auf die unterschiedliche Qualität der Klassi-

fikation auf unterschiedlichen Stadtstrukturen konnte gezeigt werden, dass weniger deutlich gegliederte Stadtstrukturen (informelle Siedlungen, starke Durchgrünung) mit geringerer Güte erfasst werden als beispielsweise die klaren Strukturen in europäischen Zentren. Moderner Städtebau sorgt weltweit für eine zunehmend uniforme Gestaltung der Bevölkerungszentren, zumindest, was die physischen Strukturen als entscheidende Merkmale im Hinblick auf die Radarfernkundung betrifft. Unterschiede zeichnen sich lediglich in den einnehmenden Flächenanteilen unterschiedlicher Stadtstrukturen ab. Hier sei auf die Abwesenheit informeller Siedlungsbereiche innerhalb mitteleuropäischer Städte oder die ausufernden Anteile städtischer Bereiche mit Vorstadt-Charakter in den Bevölkerungszentren Nordamerikas hingewiesen. Somit kann festgestellt werden, dass eine räumliche Übertragbarkeit der vorgestellten Methodik auf alle untersuchten urbanen Gebiete gegeben ist, lediglich die zu erzielende Güte ist von den Flächenanteilen einzelner Stadtstrukturtypen abhängig.

5.2.2 Übertragung in der Zeit

Bisher konnte gezeigt werden, dass die vorgestellte Methodik eine gute Eignung zur Anwendung auf verschiedene Regionen zeigt, und auf welche Limitierungen dabei zu achten ist. Im Folgenden werden auf drei Testgebieten Siedlungsmasken analysiert, deren Ausgangsdaten zu unterschiedlichen Terminen aufgenommen wurden. Analog zur bisherigen Vorgehensweise werden zunächst die Ergebnisse der Genauigkeitsanalysen vorgestellt, um dann, darauf aufbauend, weitergehende Untersuchungen der Ursachen für Fehlinterpretationen vorzustellen. Diese Analysen wurden auf den Testgebieten BUE, PAR und PBE durchgeführt und basieren auf den *Stripmap*-Datensätzen BUE1+2, PAR1+2 sowie PBE1-3 (vgl. auch Tab. A.1 in Anhang A). Tabelle 5.5 zeigt die Ergebnisse der Genauigkeitsanalysen der einzelnen Masken.

Validierung Die Gesamtgenauigkeiten der einzelnen Masken liegen alle bei über 90%. Die maximale Differenz zwischen den Masken der einzelnen Testgebiete findet sich mit 2% für PBE. Alle Aufnahmetermine eignen sich gleichermaßen für die Erfassung bebauter Areale. Die Ergebnisse der einzelnen Testgebiete zeigen zudem jeweils einheitliche Tendenzen zur Über- bzw. Unterklassifikation, eine Ausnahme hiervon

Tabelle 5.5: Ergebnisse der Tests zur zeitlichen Übertragbarkeit der pixelbasierten Erfassung bebauter Areale aus TerraSAR-X *Stripmap* Daten.

Testgebiet	Aufnahme	Gesamt- genauigkeit [%]	Kappa	Hersteller	Nutzer
BUE1	15.03.2009	96,5	0,929	97,2	95,5
BUE2	12.07.2009	95,3	0,959	94,7	96,1
PAR1	15.08.2009	92,5	0,845	95,9	86,1
PAR2	14.11.2009	91,7	0,825	89,7	88,8
PBE1	03.07.2008	92,0	0,839	99,0	84,4
PBE2	05.08.2008	94,0	0,878	97,1	89,4
PBE3	18.02.2010	93,2	0,858	87,5	95,8

ist die Szene PBE3. Die Umkehrung des Verhältnisses von Hersteller- zu Nutzergenauigkeit für PBE3 kann durch die Witterungsbedingungen zum Aufnahmezeitpunkt erklärt werden: Deutschlandweit herrschten Niedrigtemperaturen, die Seen im Aufnahmegebiet waren gefroren, ihr Rückstreuverhalten dementsprechend verändert (vgl. Abb 5.5 auf Seite 117).

Detailanalysen In einem nächsten Schritt wurden die Siedlungsmasken der einzelnen Testgebiete miteinander verglichen. Für alle Testgebiete wurde analysiert, ob mit der Zeit (von Zeitpunkt a zu b) eine Veränderung erfasst wurde oder nicht. Von Interesse sind dabei die jeweiligen Flächenanteile dieser beiden Kategorien, und im Weiteren dann insbesondere diejenigen Bereiche, in denen Veränderungen erfasst wurden.

Tabelle 5.6 gibt einen Überblick über die Flächeninhalte der einzelnen Szenen sowie derjenigen Flächenanteile, auf denen eine veränderte Interpretation bezüglich bebauten Areals gefunden wird. Erwartungsgemäß zeigen sich aufgrund der relativ kurzen Zeitspannen, die zwischen den jeweiligen Aufnahmen liegen, nur geringe Flächenanteile (3,4% bis 9,6%), auf denen eine Veränderung interpretiert wird. In Betracht der Zielklassen 'bebautes Areal' und 'nicht bebautes Areal' und den bereits gut entwickelten Untersuchungsgebieten, erscheinen auch diese Änderungsraten sehr hoch. Weitere Untersuchungen sollen daher zeigen, welche Ursachen für fehlinterp-

Tabelle 5.6: Größe der Untersuchungsgebiete und interpretierte Veränderungen bei der Untersuchung zur zeitlichen Übertragbarkeit der entwickelten Methode zur Erfassung bebauter Areale.

Testgebiet	Szenen	Gesamt- fläche [km ²]	Veränderung [km ²]	[%]
BUE	BUE1/BUE2	1642,2	56,5	3,4
PAR	PAR1/PAR2	371,9	35,8	9,6
PBE	PBE1/PBE2	984,5	37,1	4,1
PBE	PBE2/PBE3	894,5	63,0	7,0
PBE	PBE1/PBE3	894,5	68,0	7,6

tierte Veränderungen vorliegen: Von jeder Differenzmaske wurden hierzu 80 Bereiche mit vergleichsweise großer Fläche ausgewählt, auf denen eine veränderte Interpretation bezüglich der Bebauung gefunden wurde. Die Flächenbeschränkung wurde vorgenommen, um Veränderungen auf Grund technischer Limitierungen auszugrenzen, wie beispielsweise geänderte Aufnahmegeometrien, die sich lediglich kleinräumig auswirken.

Die Analyse dieser Flächen zeigt, dass sich in der Tat lediglich für 0% (PBE) bis 13,8% (BUE) der gefundenen Veränderungen eine reale Entsprechung finden lässt (vgl. Tab. 5.7). Die Areale, auf denen zwar eine veränderte Interpretation gefunden wurde, auf denen jedoch real keine Veränderung stattgefunden hat, werden im weiteren Verlauf näher untersucht. Dabei konnten sechs Kategorien identifiziert werden:

- A Übergangszone Wasser/Land
- B Sonstige Übergangszonen
- C Nicht natürliche Veränderungen
- D Natürliche Veränderungen
- E Aufnahmebedingte Einflüsse
- F Oberflächenbeschaffenheit

Kategorie A beinhaltet insbesondere solche Fehlinterpretationen, die im direkten Umfeld der Übergangsbereiche von Wasserflächen zu Land vorkommen. Wie in Abschnitt 5.1.1 bereits dargelegt, ist hier eine häufige Fehlerquelle zu finden. Die veränderte Interpretation dieser Bereiche ist vorwiegend auf unterschiedliche Wasserstände zurückzuführen. In Kategorie B werden alle anderen Fehlinterpretationen im Zusammenhang mit Übergangszonen, wie beispielsweise Wald im Übergang zu Wiesen, gefasst. Eine veränderte Interpretation wird hier insbesondere aufgrund von Änderungen der Rückstreueigenschaften, wie sie durch Belaubung oder Bodenbearbeitung auftreten können, zwischen den einzelnen Aufnahmeperioden vorgenommen.

Tabelle 5.7: Flächenanteile, relativ und absolut, auf denen eine reale Veränderung im Sinne der vorgestellten Klassifikationsmethode erfasst wird. Ebenfalls aufgeführt sind die häufigsten Fehlerkategorien, die innerhalb der jeweiligen Veränderungsmaske gefunden wurden.

Datensätze	Flächen mit realer Veränderung [%]	[km²]	wichtigste Fehlerkategorien
BUE1/BUE2	13,8	7,77	B; A; C
PAR1/PAR2	6,3	2,26	B/D; C; B/E
PBE1/PBE2	1,3	0,46	B/D; B; A/D
PBE2/PBE3	0,0	0,0	B/D; B; A/D
PBE1/PBE3	8,8	5,95	B/D; B; A/D

Im Kontext urbaner Räume sind häufig Fehlinterpretationen der Kategorie C zu finden. Hierunter fallen von Verkehrsmitteln jeder Art erzeugte Rückstreuungen oder auch temporäre Aufbauten wie Festzelte, die eine hohe Rückstreuung erzeugen und als DBC klassifiziert werden.

In Kategorie D werden alle Fehlinterpretationen zusammengefasst, die auf natürliche Veränderungen der Landbedeckung zurückzuführen sind, beispielsweise im Baumbestand oder in der landwirtschaftlichen Nutzung. Unter Kategorie E fallen all jene Fehler, die durch veränderte Aufnahmebedingungen entstehen, wie beispielsweise dem Einfallswinkel i . Veränderungen dieser Parameter können aufgrund der Art der Bildgenerierung zu einer veränderten Wiedergabe einzelner Strukturen führen. In Kategorie F finden sich jene Fehlinterpretationen, die durch eine veränderte Oberflächenbeschaffenheit verursacht werden. Darunter fallen die unterschiedliche Inter-

Tabelle 5.8: Relative Häufigkeiten der Fehlerkategorien.

Kategorie	A	B	C	D	E	F
Häufigkeit [%]	12	14	13	2	0	4
Mischkat.	A/C	A/D	B/C	B/D	B/F	D/F
Häufigkeit [%]	23	11	7	6	5	4

pretation von Wäldern in belaubtem oder laubfreiem Zustand sowie Veränderungen, die aufgrund unterschiedlicher Bodenbearbeitung auftreten (anschauliche Beispiele hierzu bei Esch (2006)).

Die Kategorien A und B können zwar strenggenommen auch in andere Kategorien eingebunden werden, aufgrund ihrer großen Bedeutung werden sie jedoch gesondert aufgeführt. Viele Fehlinterpretationen basieren auf einer Kombination zweier oder mehr der genannten Kategorien.

Tabelle 5.7 zeigt neben den Flächenanteilen, auf denen eine reale Änderung der Landbedeckung im Sinne der Klassifikation interpretiert wird, auch die Fehlerkategorien, denen auf den einzelnen Veränderungsmasken die größten Flächenanteile zugesprochen werden. Eine genauere Auflistung der Häufigkeit der auftretenden Fehlerkategorien liefert Tabelle 5.8.

Bewertung Wie aus der Auflistung hervorgeht, sind die Kategorien A, B und C sowie Kombinationen dieser Fehlerkategorien die häufigsten Ursachen für irrtümlich interpretierte Veränderungen. Insgesamt sind über 91% aller Fehlinterpretationen auf diese Ursachen zurückzuführen. Es zeigt sich somit, dass auch in Bezug auf die Erfassung von Veränderungen des bebauten Areals eine Hauptfehlerquelle (etwa 78%) in den Übergangsbereichen von Landbedeckungen mit unterschiedlicher Rückstreucharakteristik liegt. Zudem spielen temporäre Veränderungen (Kategorie C) mit etwa 13% im abgebildeten Raum eine große Rolle. Angesichts der großen Unterschiede im Rückstreuverhalten, die temporäre Veränderungen im urbanen Raum verursachen, überrascht diese Zahl nicht.

Aufnahmebedingte Einflüsse (Kategorie E) haben nur geringe Auswirkungen auf die Veränderungsanalyse. Dies ist in den flächenmäßig geringen Abweichungen be-




Abbildung 5.5: Beispiel der zeitlichen Übertragung der Siedlungserfassung im Testgebiet PBE. Zu sehen ist der große Wannensee im Südwesten von Berlin. Deutlich zu erkennen sind die Unterschiede in der Abbildung des Wannsees zum 18.02.2010. Zu dieser Zeit war der See komplett zugefroren. Dies führt an den Ufern zu einer Verringerung der Fehlinterpretationen.

gründet, die durch solche Einflüsse zu beobachten sind. Ein Beispiel für die unterschiedliche Erfassung von bebauten Arealen mit der Zeit wird in Abbildung 5.5 für einen Ausschnitt des Testgebiets PBE gegeben.

5.2.3 TerraSAR-X *Spotlight*

Im vorangegangenen Abschnitt sind Schwierigkeiten besprochen worden, die im Kontext innerstädtischer Slums sowie bebauter Areale in weniger entwickelten Regionen auftreten. Auf diesen Schwierigkeiten liegt das Hauptaugenmerk bei der Methoden-

übertragung auf TSX-SL-HR Daten, da diese in der Lage sind, die urbanen Strukturen noch feiner abzubilden als die TSX-SM Daten, was ein Vorteil in diesen Regionen sein kann. Neben München als Standarduntersuchungsraum fiel daher die Wahl der Untersuchungsräume auf kleinere afrikanische Städte (vgl. Kapitel 3.1), in denen unter anderem auch informelle Siedlungen zu finden sind.

Validierung Insgesamt konnte über alle Testgebiete eine Gesamtgenauigkeit von etwa 88% bei einem Kappa von 0,755 erreicht werden (vgl. Tab. 5.9). Die Betrachtung der Hersteller- und Nutzergenauigkeiten deuten mit Werten von 83,3% bzw. 94,4% auf eine Unterklassifizierung des Siedlungsraumes bei verhältnismäßig sicherer Zugehörigkeit der als Siedlung klassifizierten Bildelemente zu dieser Klasse. Im Einzelnen überrascht zunächst die vergleichsweise schlechte Klassifikationsgenauigkeit (79% Gesamt) für das Testgebiet *MUC*. Auch das Kappa von 0,58 deutet auf eine unbefriedigende Genauigkeit auf diesem Testgebiet: Viele kleinere Bereiche werden nicht als bebautes Areal erfasst, hervorgerufen durch das homogene Erscheinungsbild von Flachdächern oder Abschattung wichtiger Eckreflektoren durch Vegetation (vgl. Abschnitt 5.1.1). In dem durch die niedrigere Auflösung verkleinerten Suchradius w_{ar} werden nicht genügend DBC gefunden, um UA korrekt klassifizieren zu können. Kleinere Flächen um die Isar oder innerhalb von Parkanlagen hingegen werden als bebautes Areal überklassifiziert. Hier werden bei geringerer Auflösung mehr DBC im Suchradius w_{ar} gefunden als bei der Verwendung der *Stripmap* Daten. Ursächlich für beide Arten der Fehlklassifikation ist somit auf MUC die geringere geometrische Auflösung. Insgesamt zeigt sich, dass auf diesem Testgebiet die Erfassung bebauten Raumes besser über TSX-SM Daten vorgenommen werden kann.

Gute Ergebnisse konnten für die vier afrikanischen Testgebiete, die allesamt eine Güte von über 85% zeigen (*CAL* 95,0%; *GAB* 85,4%; *HAR* 91,0%; *KAM* 88,4%), erreicht werden. Bis auf *CAL* zeichnen sich alle Testgebiete durch eine Unterklassifikation des bebauten Areals aus. Bei den Testgebieten *GAB*, *HAR* und *KAM* ist diese sehr stark ausgeprägt, mit Nutzergenauigkeiten dicht an 100% und Hersteller-genauigkeiten unter 85% (Tab. 5.9). Die Unterklassifizierung ist überwiegend der Nichterfassung von Slums geschuldet. Auf den afrikanischen Testgebieten können insgesamt bessere Genauigkeiten erzielt werden als über die Verwendung von TSX-SM

Tabelle 5.9: Klassifikationsgüten der pixelbasierten Erfassung bebauter Areale auf Basis von TerraSAR-X *Spotlight* Daten.

Testgebiet	Gesamt- genauigkeit [%]	Kappa	Hersteller [%]	Nutzer [%]
CAL	95,0	0,900	96,7	93,2
GAB	85,4	0,708	77,4	100
HAR	91,0	0,820	85,2	99,2
KAM	88,4	0,768	81,8	98,8
MUC	79,0	0,580	78,0	80,8
Gesamt	87,8	0,755	83,3	94,4

Daten auf Testgebieten dieses Kontinents.

Bewertung Über alle Testgebiete konnte quantitativ der *error of omission* auf Kosten des *error of commission* verringert werden. Qualitativ sind die Fehlerquellen identisch mit den bei der Anwendung der TSX-SM Daten identifizierten. Das Ziel, schlecht entwickelte niedrige Bebauung (*Slums*) anhand höher aufgelöster Daten besser abbilden zu wollen, kann nur in geringem Maße erreicht werden. Die Frage nach der Übertragbarkeit der Methodik auf die höher aufgelösten Daten des SL-Modus jedoch kann, bei Klassifikationsgüten zwischen 79% und 95%, positiv beantwortet werden. Insbesondere die gute Qualität der Klassifikation auf den afrikanischen Testgebieten überzeugt. Hier muss allerdings darauf verwiesen werden, dass im Zuge der Verwendung der TSX-SL Daten lediglich innerstädtische Areale getestet werden konnten, während bei der Verwendung von TSX-SM Daten gerade die außerstädtischen Areale den Großteil der Fehlinterpretationen verursachten. Ein Vergleich mit dem Ergebnis, das Stasolla und Gamba (2008a) für das Testgebiet Pavia (Italien) auf Basis von TSX-SL Daten erzielen, fällt hingegen ungünstig aus. Mit 95% Gesamtgenauigkeit und einem Kappa von 0,78 liegt die Klassifikationsgüte deutlich höher.

5.2.4 TerraSAR-X *ScanSAR*

Die Übertragung der pixelbasierten Methodik zur Erfassung von Siedlungsräumen auf die niedriger aufgelösten Daten des TSX-SC-Modus soll eine rasche, flächendeckende Analyse bebauter Areale ermöglichen. Auf Basis dieser Daten können mit einem Datensatz Räume von bis zu 2100 km² untersucht werden. Somit zeigen diese Datensätze eine hervorragende Eignung für großräumige Untersuchungen.

Validierung Tabelle 5.10 gibt einen Überblick über die Ergebnisse der Genauigkeitsanalysen basierend auf den Siedlungsmasken dieser Datensätze. Über alle Untersuchungsgebiete gesehen, ergibt sich eine Genauigkeit von 92,5% bei einem Kappa von 0,850. Im Gegensatz zu den Ergebnissen der Übertragung auf SL-HR Daten (vgl. Tab. 5.9) neigt die Methodik auf SC-Daten zur Überklassifizierung. Auffällig ist der vergleichsweise niedrige Wert von 87,0% in der Gesamtgenauigkeit für *MUC*, hervorgerufen durch die niedrige Nutzergenauigkeit von 76,6%. Im südlichen Teil erreicht das Testgebiet die Alpen, mit den bereits in Abschnitt 5.1.1 besprochenen Folgen der Überklassifikation von bebautem Areal, bedingt durch das Nebeneinander von Überlappung und Abschattung.

Tabelle 5.10: Ergebnisse der pixelbasierten Erfassung bebauter Areale aus TerraSAR-X *ScanSAR* Daten.

Testgebiet	Gesamtgenauigkeit [%]	Kappa	Hersteller	Nutzer
BUE	94,5	0,889	95,7	93,5
IST	96,4	0,928	98,4	94,5
MUC	87,0	0,739	95,9	76,6
SYD	90,2	0,804	94,9	85,7
Gesamt	92,5	0,850	96,1	88,8

Für alle anderen Untersuchungsgebiete konnte jeweils eine Gesamtgenauigkeit von über 90% erzielt werden, wobei sich die Neigung zur Überklassifizierung nur noch für *SYD* deutlich zeigt. Einmal mehr liegt die Ursache dafür im stark reliefierten Umland der Stadt Sydney.

Weitere Überklassifizierungen zeigen sich in den Übergangsbereichen von Wasser zu Land, von Stadt zu Umland sowie bedingt durch vereinzelte schwimmende Objekte inmitten von Wasserflächen. Von der technischen Seite her gesehen ist, wie schon für die SM-Daten beschrieben, die Hauptursache für Überklassifizierungen in Bildbereichen zu sehen, die Grenzlinsen zwischen Arealen mit geringer und hoher Rückstreuung darstellen: beim Übergang von Wasser (geringe Rückstreuung) zu Land (höhere Rückstreuung), von Umland (relativ gering) zu Stadt (teils enorme Rückstreuung).

Die hohen Herstellergenauigkeiten deuten auf geringe Unterklassifizierungen. Sie finden sich vorwiegend in städtischen Bereichen mit entweder lockerer, stark mit Vegetation durchsetzter Bebauung, wie beispielsweise typisch für Villenviertel in Deutschland, oder in innerstädtischen Bereichen mit niedriger, sehr dichter Bebauung (informelle Siedlungen).

Bewertung Die Übertragung der Methodik auf den *ScanSAR* Modus kann als gelungen bezeichnet werden. Durchweg konnte eine hohe Qualität der Siedlungsmaske erzielt werden. Einzig für den verstärkten negativen Einfluss des Reliefs auf die Erfassung bebauter Areale, insbesondere im Testgebiet MUC, könnte eine weitere Anpassung vorgenommen werden. In diesen Bereichen kann über die Einbindung der Informationen eines digitalen Geländemodells eine weitere Verbesserung erzielt werden — ein solches kann in die Datenlieferung von TSX Daten integriert sein. Jedoch würde dadurch die Verarbeitungsgeschwindigkeit herabgesetzt und die Komplexität der Methodik leicht erhöht.

5.2.5 ALOS-PALSAR

Validierung Die Umsetzung der pixelbasierten Methodik zur Erfassung von bebauten Arealen auf PALSAR-Datensätze ist, wie in Abschnitt 4.2.3 beschrieben, gelungen. Tabelle 5.11 stellt die erzielten Genauigkeiten für die beiden Testgebiete Rhein-Neckar-Region (RNR) sowie IST den auf TSX *Stripmap* Daten erzielten Ergebnissen gegenüber. Im Vergleich zu den sehr guten TSX-Ergebnissen fällt die Qualität der PALSAR-Masken in jeder Hinsicht ab. Jedoch können auch für diese Klassifikatio-

nen mit Kappa-Werten höher 0,6 und Gesamtgenauigkeiten von 85,9% für RNR bzw. 81,6% für IST zufriedenstellende Ergebnisse erzielt werden.

Tabelle 5.11: Vergleich der Ergebnisse der Detektion bebauter Areale basierend auf TSX-*Stripmap* und ALOS-PALSAR.

	Rhein-Neckar		Istanbul	
	TSX	ALOS	TSX	ALOS
Hersteller [%]	97,8	79,6	98,0	85,8
Nutzer [%]	92,7	84,9	93,0	76,1
Gesamt [%]	95,3	85,9	96,0	81,6
Kappa	0,91	0,71	0,92	0,63

Die Analyse der Fehlklassifikationen zeigt, dass die veränderte Rückstreucharakteristik des L-Bandes zu neuen Fehlerquellen führt. Eine solche ist in mit Pflanzen dicht bewachsenen Entwässerungsgräben, die parallel zur Azimuth-Richtung verlaufen, zu sehen. Da im Gegensatz zum X-Band Radarstrahlung im L-Band die Vegetation durchdringt, finden sich an diesen Stellen in der PALSAR-Aufnahme Linien höherer Rückstreuung, die durch kleinräumige Hangverkürzung oder Überlappung erzeugt werden. In Verbindung mit der geringen Rückstreuung der direkt an die Gräben angrenzenden Felder entsteht eine hohe Textur, die zur Klassifikation als DBC führt. Eine weitere Fehlerquelle ist in Weinbergen auszumachen, diese sind weiträumig im östlichen Bereich von RNR zu finden. Die Rebzeilen vieler Parzellen innerhalb dieser Weinberge sind parallel zur Azimuth-Richtung orientiert. Diese Anordnung schließt eine identische Richtung der Drahtrahmen, die als Rankhilfe für die Reben fungieren, ein. Dieser spezielle Aufbau der Drähte wiederum ruft eine starke Rückstreuung der Radarstrahlung hervor, ein Effekt, den man bei der Anordnung metallischer Objekte in Abständen des Vielfachen der halben verwendeten Wellenlänge beobachten kann (Richards 2009). Auch hier ergeben sich, in Verbindung mit den sie umgebenden dunkleren Flächen, sehr hohe Texturwerte, so dass diese Fläche weiträumig fehlerhaft als Siedlungsgebiete (DBC bzw. PUS) klassifiziert werden.

Weitere Klassifikationsfehler bei der Verwendung des L-Bandes treten im Kontext dichter Wälder auf. Auch hier ist die bessere Durchdringung der Blattanteile der Vegetation der ausschlaggebende Faktor. Senkrecht stehende Baumstämme bilden in Kombination mit dem Boden einen Doppelreflektor mit hohem Rückstreuquer-

schnitt. So erscheinen diese Bereiche als helle Areale im L-Band. Auch hier führt die Kombination von hellen Pixeln und dunkleren in ihrem Umfeld zu hohen Texturen. Die Textur- und Intensitätswerte in diesen Bereichen sind nicht ausreichend, um als DBC klassifiziert zu werden, in Bereichen jedoch, in denen Wälder direkt an Siedlungsflächen angrenzen, werden solche Waldflächen häufig fehlerhaft als PUS oder UA klassifiziert.

Bewertung Die Tests der Übertragbarkeit auf Datensätze des PALSAR-Sensors zeigen, dass es prinzipiell möglich ist, anhand von Intensität und Textur eine Erfassung von bebauten Arealen auf Basis von L-Band-SAR vorzunehmen. Gegenüber TSX-SM Daten ist allerdings eine erhebliche Verschlechterung der Klassifikationsgüte zu beobachten. Die Kappa-Werte deuten für beide Untersuchungsgebiete auf zufriedenstellende Klassifikationsergebnisse. Auch gegenüber den in der Auflösung ähnlichen TSX *ScanSAR* Daten ist eine Verschlechterung der Klassifikationsgüte zu beobachten. Dies ist ein Indikator dafür, dass bei der Anwendung der hier vorgestellten Methodik das verwendete Radarband einen größeren Einfluss auf das Ergebnis hat als die verwendete Auflösung. Die einfache Übertragung der Methodik führt nicht zu einem befriedigenden Ergebnis. Um eine verbesserte Erfassung von bebauten Arealen zu gewährleisten, ist eine weitere Anpassung auf das L-Band unumgänglich.

Stasolla und Gamba (2008b) erzielten auf einem kleinen Testgebiet um Pavia (Italien) auf Basis von ALOS-PALSAR Daten eine Gesamtgenauigkeit von 97,8% bei einem Kappa von 0,79. Damit erreichen die Autoren eine deutlich höhere Genauigkeit. Im Detail bleibt jedoch festzustellen, dass dieses Ergebnis in weiten Teilen auf die gute Klassifikationsgenauigkeit in größeren zusammenhängenden Stadtbereichen erzielt wird. Periphere, dünnbesiedelte Areale werden von Stasolla und Gamba (2008b) nur unzureichend erfasst.

5.3 Erfassung einfacher Landbedeckungstypen

In diesem Abschnitt werden nun die Ergebnisse der in Abschnitt 4.3 vorgestellten Methodik zur Erstellung einer Basisklassifikation anhand TSX-SM Daten vorgestellt.

Histogrammanalysen Wie in Abschnitt 4.3 beschrieben, ist der erste Schritt des pixelbasierten Ansatzes zur Klassifikation der Landbedeckung in TSX Daten die Histogrammanalyse der Intensitäts- und Texturwerte für ausgewählte Testgebiete jeder Klasse. Diese Analysen dienen der Bestimmung von Schwellwerten zur Klassentrennung. Die aus diesen Analysen resultierenden sechs Schwellwerte sind in Tabelle 5.12 für jedes Testgebiet aufgeführt. Für jeden Schwellwert können, über alle Testgebiete betrachtet, bis auf wenige 'Ausreißer' (in Tab. 5.12 fett gedruckt), relativ kleine Schwankungen gefunden werden. Dies kann als erstes Indiz für die Robustheit der schwellwertbasierten Klassifikation gesehen werden. Zusätzlich zu diesen szenenspezifischen Schwellwerten wurden nach dem gleichen Verfahren globale Schwellwerte ermittelt.

Tabelle 5.12: Ermittelte Schwellwerte zur Trennung der Landbedeckungsklassen (automatisiert).

Testgebiet	T_{Ut}	T_{Wt}	T_{Ot}	T_{Ui}	T_{Wi}	T_{Oi}
BUE	0,22	0,04	0,03	119	104	63
CTU	0,22	0,04	0,02	132	124	57
HYD	0,16	0,04	0,02	140	121	58
IST	0,22	0,05	0,03	127	103	50
LOS	0,19	0,04	0,01	160	143	59
MEX	0,18	0,03	0,02	135	105	56
MUC	0,16	0,04	0,02	120	100	44
NBO	0,18	0,04	0,03	130	103	52
PDG	0,19	0,06	0,00	170	142	78
PHX	0,14	0,03	0,02	129	106	53
SYD	0,22	0,03	0,01	132	107	53
THR	0,23	0,05	0,04	133	108	54
Global	0,19	0,04	0,02	136	107	54

Validierung Die pixelbasierte Landbedeckungsklassifikation wurde für die vier Testgebiete BUE, LOS, MUC und PDG vorgenommen. Der Einfluss der zwei unterschiedlichen Bestimmungsmethoden von C_F (theoretisch oder automatisch; vgl. Abschnitt 2.2.4) wurde untersucht und die Klassifikation sowohl auf Basis der Szenen spezifischen (überwacht) als auch auf Basis der global ermittelten Schwellenwerte (unüber-

wacht) durchgeführt.

Aus den kombinierten Vorgehensweisen ergeben sich für jedes Testgebiet vier Klassifikationen, die alle im einzelnen durchgeführt und auf ihre Qualität hin untersucht wurden. Für alle Testgebiete konnte dabei ein zufriedenstellendes Ergebnis erzielt werden (Tab. 5.13). Die Gesamtgenauigkeiten liegen in einer Spanne von 85,6% für MUC (beide überwachten Verfahren) und 76,8% für PDG (automatisch; unüberwacht).

Tabelle 5.13: Gesamtgenauigkeiten [%] und (in Klammern) die Kappa-Werte der Landbedeckungsklassifikationen für die angegebenen Testgebiete.

Testgebiet	theoretisch		automatisch	
	unüberwacht	überwacht	unüberwacht	überwacht
BUE	79,4 (0,718)	78,2 (0,704)	81,0 (0,738)	78,2 (0,704)
LOS	80,6 (0,722)	79,8 (0,720)	78,8 (0,720)	79,8 (0,720)
MUC	83,8 (0,776)	85,6 (0,799)	85,0 (0,792)	85,6 (0,799)
PDG	79,4 (0,685)	82,1 (0,724)	76,8 (0,653)	80,2 (0,699)

Eine genaue Betrachtung der Klassifikationsergebnisse zeigt, dass, über alle vier Testgebiete gesehen, für München mit um die 85% durchweg die besten Werte erzielt werden. In der Gesamtgenauigkeit unterscheiden sich die anderen Testgebiete nur unwesentlich; sie liegen im Mittel um die 79%. Für MUC wird aufgrund der schärferen Abgrenzung einzelner Landbedeckungsklassen gegeneinander, z.B. 'Wald' von 'Offenland', eine höhere Klassifikationsgüte erreicht. Abbildung 5.6 zeigt, als Beispiel, das Ergebnis der unüberwachten Klassifikation für MUC; die Bestimmung von C_F erfolgte dabei automatisiert.

Über alle vier Testgebiete gesehen zeigen alle Klassifikationsvarianten relativ stabile Gesamtgenauigkeiten. Die Schwankungsbreite dieses Maßes über alle Varianten beträgt pro Testgebiet meist nicht mehr als 3%. Lediglich für PDG wird in der unüberwachten, automatisierten Variante eine höhere Abweichung zu den anderen drei Varianten festgestellt. Hier verstärken sich die negativen Einflüsse der unüberwachten Variante mit dem der automatisierten Bestimmung von C_F . Auf diesem Testgebiet sind, je nach Variante, große Unterschiede in der Dateninterpretation bezüglich der Klassen 'Wasser', 'Offenland' und 'Wald' zu finden. Anhand des theoretischen Ansatz-




Abbildung 5.6: Beispiel eines Ergebnisses der unüberwachten Landbedeckungsklassifikation auf dem Testgebiet MUC. Die Bestimmung von C_F erfolgte hier automatisiert. Die Gesamtgenauigkeit dieser Klassifikation liegt bei 85% .

zes zur Bestimmung von C_F kann über alle Testgebiete und Klassifikationsverfahren eine mittlere Genauigkeit von 81,1% erreicht werden — gegenüber 80,7% Gesamtgenauigkeit für den automatisierten Ansatz. Da die verwendeten Schwellwerte jeweils separat ermittelt wurden, waren keine großen Unterschiede zu erwarten. Die beiden überwachten Klassifikationen der Testgebiete BUE, LOS und MUC stimmen exakt überein.

Vergleicht man die Ergebnisse der überwachten Klassifikationen mit denen der unüberwachten, zeigt sich lediglich auf PDG ein deutlicher Zusammenhang. Die Gesamtgenauigkeit der die überwachten Varianten ist höher als die der unüberwachten. Auf allen anderen Testgebieten ist keine eindeutige Tendenz auszumachen. Im Durchschnitt wird anhand der überwachten Varianten eine Gesamtgenauigkeit von 81,2% erzielt, gegenüber 80,6% unüberwacht. Bemerkenswert ist, dass die überwachten Varianten nicht durchgängig die besseren Ergebnisse liefern. Allerdings sind die Unterschiede (bis auf PDG) so gering, dass keine weiteren Aussagen getroffen werden sollen.

Ein Blick auf die klassenbezogenen Ergebnisse (Tabelle C.1 im Anhang) zeigt, dass die Klassen 'Stadt' und 'Wasser' im Durchschnitt mit über 90% klassifiziert werden, während die Klassen 'Wald' und 'Offenland' deutlich schlechtere Genauigkeiten aufweisen. Der Grund für die geringeren Ergebnisse dieser beiden Landbedeckungsklassen ist, dass beide große Überlappungsbereiche in den Histogrammen aufzeigen (vgl. Abb. 4.7 und 4.8), und es anhand des *majority*-Filters nicht gelingt, diese Überschneidungen zu trennen. Zudem finden sich in den einzelnen Testgebieten Besonderheiten, die eine Trennbarkeit der Klassen 'Wald' und 'Offenland' erschweren, vorwiegend der Fall für BUE, LOS und PDG. Hier unterscheiden sich beide Klassen sowohl in der Nutzer- als auch in der Herstellergenauigkeit von den anderen Klassen erheblich (vgl. Tab. C.1 im Anhang). Zurückzuführen ist dies auf die Struktur der Wälder, deren charakteristischer Laubbesatz und Baumabstände eine Radarrückstreuung erzeugen, die sich von derjenigen der bewirtschafteten Wälder Mitteleuropas unterscheidet. Zudem ist speziell im Testgebiet PDG zu berücksichtigen, dass das Rückstreusignal der Waldgebiete vom Relief überlagert wird. Der größte Teil der Waldgebiete liegt in stark reliefiertem Areal. Aufgrund dieser überlagerten Informationsgehalte zeichnen sich diese Bereiche durch eine erhöhte Homogenität aus. Daraus ergibt sich ein gerin-

ger Wert für die Textur, was wiederum dazu führt, dass derartige Waldgebiete der Klasse 'Offenland' zugewiesen werden.

Eine Besonderheit des Untersuchungsgebietes PDG sind die mit 71,1% vergleichsweise geringen Nutzergenauigkeiten für Wasser in den unüberwachten Varianten. Dieser Umstand ist dem aufgerauten 'Wasser' im Küstenbereich geschuldet. Eine solche windbedingte Aufrauung erzeugt partiell eine höhere Rückstreuung und damit eine erhöhte Textur, die untypisch für 'Wasser' ist. Bei Anwendung der überwachten Verfahren kann dieser Fehler verringert werden.

Bewertung Ein Vergleich mit den Ergebnissen, die Bruzzone et al. (2004) auf Basis eines überwachten Verfahrens anhand multitemporaler ERS-1 Daten erzielen konnten, fällt auf den ersten Blick ungünstig aus. Bei identischer Klassenauswahl — die Klasse 'Offenland' entspricht der Klasse 'Felder' bei Bruzzone et al. (2004) — liegt mit 92,2% Gesamtgenauigkeit dieses Verfahren um 6,2% über dem besten hier vorgestellten Ergebnis, im Durchschnitt um 11,3%. Allerdings fehlt für diese Methodik ein Nachweis der Übertragbarkeit; es wurde lediglich ein Testgebiet analysiert, und eine Automatisierbarkeit ist aufgrund der überwachten Anwendung nicht gegeben. Zudem können über die Auswertung einer Zeitreihe temporäre Effekte, die in monotemporalen Datensätzen zu Fehlinterpretationen führen können (vgl. dazu auch Abschnitt 5.2.2), ausgeschaltet werden. Letztlich kann, ohne diese Effekte im Einzelnen genauer beziffern zu können, festgehalten werden, dass anhand des hier vorgestellten neuen Verfahrens gute Ergebnisse erzielt werden können. Dies bestätigt auch ein Vergleich mit den Ergebnissen von Herold et al. (2005). Mit Gesamtgenauigkeiten von 73,3% und 83,2% erzielten die Autoren nicht nur eine ähnliche Güte, sondern die Einzelergebnisse der Testgebiete lagen auch in einem ähnlich weiten Schwankungsbereich.

Die Unterschiede, die sich aus der Bestimmungsmethode von C_F ergeben, sind marginal. Für weitere Klassifikationen wird daher die Verwendung der theoretischen Bestimmung von C_F empfohlen, da sie gegenüber der automatisierten eine erhebliche Zeit- und Aufwandseinsparung bedeutet. Die Vorteile des überwachten Verfahrens gegenüber dem unüberwachten fallen kaum ins Gewicht. Somit empfiehlt sich die Kombination unüberwacht/theoretisch als beste Variante zur Landbedeckungsklassi-

fikation. Sie ermöglicht eine automatisierbare Klassifikation der Landbedeckung auf Basis monotemporaler, single-polarisierter TerraSAR-X *Stripmap* Daten.

5.4 Analyse von Baugebieten

In Abschnitt 4.4 wurde eine Methodik vorgestellt, anhand derer aktuelle Baugebiete gegenüber anderen Flächen, die ebenfalls eine Veränderung zwischen zwei TSX-SL-HR Aufnahmetermen aufweisen, abgegrenzt werden können. An dieser Stelle werden nun die Ergebnisse dargestellt, die auf Basis von sechs TSX-SL-HR Datensätzen des Untersuchungsraumes München erzielt wurden. Die Aufnahmezeitpunkte der Daten liegen um den Jahreswechsel 2008/2009, überwiegend im Frühjahr 2009 (Tab. 5.14).

Tabelle 5.14: Aufnahmetermine der TSX-SL-HR Daten, die im Zuge der Tests zur Erfassung von Baustellen verwendet wurden.

Kürzel	Datum	Kürzel	Datum	Kürzel	Datum
z1	08.12.2008	z2	01.02.2009	z3	23.02.2009
z4	06.03.2009	z5	28.03.2009	z6	08.04.2009

Veränderungsanalyse Zunächst wird überprüft, welche Flächenanteile der Referenzflächen über die Veränderungsanalyse nach Schmitt et al. (2010) erfasst werden. Dazu werden diejenigen Flächenanteile, auf denen eine Veränderung identifiziert wurde, ins Verhältnis zur Gesamtfläche der jeweiligen Referenz gesetzt. Verdeutlicht wird dieses Vorgehen in Abbildung 5.7. Die ausgewählten Referenzflächen sind als Polygone dargestellt (rot: Baugebiet; grün: Rest) und repräsentieren 100%. Die Bereiche, auf denen eine Veränderung erfasst wurde, sind mit der entsprechenden Farbe ausgefüllt.

Über alle Zeitschnitte betrachtet, wird auf dem Referenzgebiet 9 (vgl. Tab. 3.2) mit etwa 60% der höchste Flächenanteil als Veränderung im Zeitschnitt z4-z5 erkannt (vgl. Abb. 5.15). Dabei bilden die Veränderungsflächen nicht ein einzelnes Objekt, sondern sind aufgesplittet in kleinere Objekte. Auffällig ist zudem, dass über alle




Abbildung 5.7: Die Variation der erfassten Veränderungsflächen zwischen zwei aufeinanderfolgenden Aufnahmeterminen. Rot kennzeichnet Baugebiete, grün Veränderungsflächen anderer Nutzung. Die farbigen Flächen zeigen die erfassten Veränderungen innerhalb des jeweiligen Testgebietes (Polygone).

Zeitschnitte betrachtet die Anteile innerhalb der Testgebiete, die als Veränderung identifiziert werden, enorm variieren. Im Mittel sind im Zeitschnitt z1-z2 mit 43% diejenigen Anteile, auf denen eine Veränderung erfasst wird, am höchsten. Innerhalb dieser Zeitspanne haben auf vielen Baustellen Rohbauarbeiten stattgefunden. In den anderen Zeitschnitten liegt dieser Anteil zwischen 35% (z4-z5) und 14% (z3-z4). Um den Zeitpunkt z3 lag im Stadtgebiet München großräumig Schnee, Bauaktivitäten konnten nur eingeschränkt vorgenommen werden. Im Zeitschnitt z3-z4 zeigen sich daher nur geringe Veränderungen auf den Referenzbaugebiete. In diesem Zeitraum sind auf einigen Referenzflächen, die keine Baugebiete zeigen, übermäßig starke Veränderungen festzustellen (vgl. Abb. 5.7).

Tabelle 5.15: Flächenanteile, die innerhalb der Referenzbaugebiete als Veränderungsfläche identifiziert werden [%]. Die Ziffern 3 bis 13 bezeichnen die jeweils untersuchten Referenzbaugebiete (Tab. 3.2).

Nr.	Untersuchungsgebiet	z1-z2	z2-z3	z3-z4	z4-z5	z5-z6
3	Lilli-Palmer-Strasse	50	21	18	41	20
4	Theresienhoehe	54	26	6	49	37
5	Hotel am Arnulfpark	53	6	2	29	29
7	Deutsche Bahn	48	24	0	23	12
8	Bernhard-Wicki-Strasse	17	33	24	7	20
9	Arnulfstrasse MB Baustelle	53	27	5	60	36
10	Arnulfstrasse 51	57	2	1	3	3
11	Arnulfstrasse 39	26	20	7	8	1
12	An der Donnersberger Bruecke	52	24	17	47	17
13	Eisnergutbogen	19	51	40	21	9
	Gesamt	43	26	14	35	23

Eine Besonderheit des Referenzgebietes 10 ist, dass hier der Rohbau innerhalb des ersten Zeitschnittes (z1-z2) fertiggestellt wurde. Nach dem 01.02.2009 (z2) fanden nur noch Maßnahmen im Innenbau statt. Für dieses Testgebiet wird lediglich für den Zeitschnitt z1-z2 ein nennenswerter Flächenanteil als Veränderung erfasst. Das Gleiche betrifft das Testgebiet 11, allerdings mit einem Zeitschnitt Verzögerung.

Merkmalsauswahl Der nächste Schritt gilt der Identifizierung der am besten zur Klassifikation von Baugebiet geeigneten Merkmale. Auf Basis der Referenzgebiete




Abbildung 5.8: Bewertung der Relevanz der untersuchten Objektmerkmale Median (MED), Mittelwert (MEAN), Minimum (MIN), Maximum (MAX) sowie Standardabweichung (STD) für die GLCM-Texturen CON, COR, DIS, ENT und HOM über die Maße MDA und MDG. Je höher der ermittelte Wert für ein Merkmal ist, desto höher seine Relevanz für die Erfassung der Zielklasse.

und unter Anwendung eines *Regressionstree*-Klassifikators wurden für die 25 zu untersuchenden Merkmale die Maße *Mean Decrease Accuracy* (MDA) und *Mean Decrease Gini* (MDG) ermittelt (siehe Abb. 5.8). Sowohl über die MDA- als auch die MDG-Analyse werden die Mediane von COR, DIS und CON eindeutig als die zur Trennung von 'Baugebiet' zu 'nicht Baugebiet' wichtigsten Merkmale identifiziert. Insgesamt gesehen, zeigen sich die Objekt-Mediane der berechneten GLCM-Maße gegenüber den anderen statistischen Maßen als diejenigen Merkmale mit der höchsten Relevanz. Lediglich für das GLCM-Maß ENT werden andere statistische Objektmaße (min, max, mean) als besser zur Klassentrennung geeignet erkannt.

Auf Basis dieser ersten Analysen werden im weiteren Verlauf die drei Merkmale COR (med), DIS (med) und CON (med) als Unterscheidungskriterien für die Trennung von aktuellen Baustellen zu Veränderungsflächen anderer Art herangezogen. Auf Basis dieser Merkmale sowie der Referenzflächen ergeben sich für das Klassifikationsverfahren folgende drei Schwellwerte: $T_{con} = 4000$, $T_{dis} = 50$, $T_{cor} = -0,062$.

Validierung Die oben genannten Schwellwerte werden in das Klassifikationsschema (4.12) eingesetzt, und auf allen Veränderungsflächen der Untersuchungsräume eine Klassifikation vorgenommen. Über alle Zeitschnitte hinweg werden 80,3% der Veränderungsflächen auf den Untersuchungsgebieten korrekt erfasst (Tab. 5.16). Die Güte der Klassifikation variiert stark über die einzelnen Zeitschnitte, von 89,1% (z5-z6) bis zu 63,8% (z3-z4). Wie bereits erwähnt, lag um den 23.02.2009 (z3) auf vielen Untersuchungsarealen Schnee. Witterungsbedingt sind nur wenige Veränderungen durch Bautätigkeiten verursacht. Andererseits zeigen Areale, die keine Baugebiete abbilden, zu diesem Zeitpunkt ungewöhnlich großflächige Veränderungen auf.

Tabelle 5.16: Genauigkeitsmaße für die Klassifikation von Baustellen, gelistet in Prozent [%] für einzelne Zeitschnitte sowie aufsummiert über alle Zeitschnitte (Alle). Die Genauigkeitsanalyse wurde auf Pixelebene vorgenommen.

Zeitschnitt	Gesamt	Hersteller	Nutzer
z1-z2	83,1	83,6	79,9
z2-z3	76,7	76,8	73,7
z3-z4	63,8	79,6	37,2
z4-z5	76,8	92,0	76,2
z5-z6	89,1	89,4	89,4
Alle	80,3	85,7	76,1

Abbildung 5.9 zeigt die Ergebnisse der objektorientierten Klassifikation von Baustellen am Beispiel ausgewählter Untersuchungsräume zu den unterschiedlichen Zeitschnitten im Vergleich zur Ausgangsszene vom 08.12.2008. Die Polygone umranden die Untersuchungsgebiete für Baustellen (rot) und andere Flächen mit Veränderung (grün). Farbige Flächen zeigen Areale, die korrekt klassifiziert wurden (grün) oder auf denen eine Fehlinterpretation (rot) stattgefunden hat. Weite Bereiche der Untersuchungsräume wurden, wie zu erkennen, korrekt erfasst. Lediglich für den Untersuchungsraum 26 werden Fehlinterpretationen zu allen Zeitschnitten gefunden. Deutlich sind die geringen Veränderungen zum Zeitschnitt z3-z4, die den Witterungsbedingungen nach dem 23. Februar zuzuschreiben sind, zu erkennen.

Die vorangehende Analyse der Klassifikationsgenauigkeit wurde auf Pixelbasis vorgenommen. Wird eine Analyse auf Basis der über die Veränderungsanalyse er-




Abbildung 5.9: Ergebnisse der Klassifikation von Baustellen zu den einzelnen Zeitschnitten. Grüne Flächen zeigen korrekt klassifizierte Veränderungsbereiche, rote Flächen weisen Fehlinterpretationen aus. Die untersuchten Testgebiete werden durch Polygone abgegrenzt — in Rot Baugebiete; in Grün andere Veränderungsflächen.

mittelten Objekte erstellt, ergibt sich ein etwas anderes Bild. Über alle Zeitschnitte hinweg betrachtet, werden etwa 68,2% aller Objekte korrekt klassifiziert. Dabei zeigt sich eine Spannweite von 65,8% (z3-z4) bis 71,4% (z4-z5). Die Gesamtgenauigkeiten liegen auf Objektebene insgesamt niedriger als auf der Pixelebene, denn die Fläche von Objekten, die bezüglich ihrer Klassenzugehörigkeit fehlinterpretiert werden, ist im Durchschnitt kleiner als die der korrekt erfassten Objekte (\varnothing 81,3m² bei 412 Objekten gegenüber \varnothing 151m² bei 847 Objekten). Bei genauer Betrachtung des Klassifikationsergebnisses (vgl. Abb. 5.9) bestätigt sich dies: Ursache hierfür ist die Verwendung des Objektmedians. Die statistische Aussagekraft dieser Kennzahl steigt mit der Anzahl der einfließenden Einzelfälle (hier: Pixel). Bei kleineren Objekten kann davon ausgegangen werden, dass die statistische Aussagekraft des Medians nicht ausreicht, um eine korrekte Klassifizierung durchzuführen.

Bewertung Mit Hilfe der Veränderungsanalyse nach Schmitt et al. (2010) können baubedingte Veränderungen auf Baustellen erfasst werden. Alle untersuchten Referenzflächen, auf denen tatsächliche Bautätigkeiten stattfanden, zeigen zu jedem Zeitschnitt ein Minimum an Veränderung. Zudem werden auch auf anderen Arealen Veränderungen angezeigt, die von Baustellen unterschieden werden müssen. Dies wird mit der vorgestellten Klassifikationsmethode erreicht. Anhand der vorgestellten Methodik können auf den ausgewählten Untersuchungsgebieten Genauigkeiten zwischen 63,8% und 89,1% erreicht werden. Die weite Spanne der erzielten Gesamtgenauigkeiten ist weitestgehend den Witterungsverhältnissen Anfang März geschuldet. Legt man lediglich die schneefreien Zeitschnitte zugrunde (z1-z2, z4-z5, z5-z6), können auf Pixelbasis durchweg Gesamtgenauigkeiten besser 76% erreicht werden.

Unter Berücksichtigung dieser Ergebnisse konnte gezeigt werden, dass über die Verwendung geeigneter Texturmaße und mittels Voruntersuchungen (hier: Veränderungsanalyse) eine weitere Gliederung des urbanen Raumes, in diesem Fall eine Unterscheidung aktiver Baustellen von anderen Arealen, die eine veränderte Rückstreuung mit der Zeit aufweisen, vorgenommen werden kann.

6

Fazit und Ausblick

In der vorliegenden Dissertationsschrift wurden verschiedene Methoden zur Klassifikation von SAR-Daten vorgestellt. Der Schwerpunkt lag dabei auf der Entwicklung und dem Test einer automatisierten Methodik zur Erfassung von bebautem Areal. In einem weiteren Schritt wurde ein Verfahren zur Erstellung einer einfachen Landbedeckungsklassifikation im Umfeld von Siedlungsräumen entwickelt. Abschließend sollen nun die gewonnenen Erkenntnisse zusammengefasst sowie ein kurzer Ausblick auf das weitere Potential der vorgestellten Methodiken gegeben.

6.1 Klassifikation von Siedlungsräumen in SAR-Daten

Die vorgestellten Verfahren zielen, aufbauend auf den Arbeiten von Esch (2006), auf die Erfassung bebauter Areale und der Klassifikation der Basislandbedeckungen im Umfeld von Siedlungsräumen. Die Klassenentscheidung basiert dabei in neuartiger Weise jeweils auf der Auswertung der Radarintensität und lokaler Texturen, die über Schätzfenster berechnet werden. Auf Basis eines *region-growing*-Verfahrens mit anschließender Generalisierung im *moving-window*-Ansatz kann die Klassifikation bebauter Areale gegenüber der von Esch (2006) vorgestellten Methodik stark beschleunigt werden. Die erzielte Klassifikationsgüte liegt mit bis zu 95,8% in dem Bereich, den auch Lisini und Gamba (2008) und Stasolla und Gamba (2008b) auf Basis von TerraSAR-X *Stripmap* Daten bei der Erfassung von Siedlungsräumen er-

reichen, wobei die Erfassung kleinerer Ansiedlungen, zumindest in gut entwickelten Regionen, ebenso gelingt wie die Abbildung zusammenhängender Stadtgebiete. Es konnte gezeigt werden, dass die erzielten Ergebnisse mit einer zufriedenstellenden Schwankungsbreite im Raum übertragbar sind. Dabei wurden verschiedene, weltweit verteilte urbane Räume getestet. Die Erfassung bebauter Areale erreicht in besser entwickelten urbanen Räumen höhere Genauigkeiten als in weniger weit entwickelten Städten Afrikas oder Asiens. Insbesondere kleinere Ansiedlungen außerhalb der Stadtgebiete oder dicht bebaute informelle Siedlungen wurden ungenügend abgebildet. Aufgrund der ungenügenden Qualität der vorliegenden Referenzdaten konnten weitere Untersuchungen auf diesen Arealen nicht vorgenommen werden. Die Landbedeckungsklassifikation im Umfeld urbaner Räume hingegen konnte mit guten Ergebnissen (bis zu 85,6% Gesamtgenauigkeit) und guter Übertragbarkeit umgesetzt werden. Ein wichtiger Faktor zur Erreichung dieser Resultate ist die Auswahl der Zielklassen. Wie schon von Bruzzone et al. (2004) festgestellt, zeigen die Klassen 'bebautes Areal' bzw. 'Siedlungsraum', 'Wald', 'Wasser' und 'Offenland' (bei Bruzzone et al. (2004) 'Felder') in verschiedenen SAR-Aufnahmen jeweils ein ähnliches Erscheinungsbild.

In Abschnitt 5.2.1 konnte gezeigt werden, dass die Methode zur Erfassung bebauter Areale für ein Monitoring von Siedlungen und deren Umfeld über die Zeit geeignet ist. Schwankungen von lediglich zwei Prozent in der Gesamtgenauigkeit deuten auf eine hohe Robustheit des Verfahrens. Die entsprechenden Tests belegen, dass, auf das gesamte Untersuchungsgebiet hin betrachtet, unterschiedliche Aufnahmegeometrien nur einen geringen Einfluss auf die Klassifikationsgüte haben. Bei der genaueren Analyse der Fehlinterpretationen wurde deutlich, dass Radarsensoren zwar in der Lage sind, weitestgehend unabhängig von Witterungsbedingungen Daten aufzuzeichnen, dass jedoch die automatisierte Interpretation der Daten, beispielsweise durch Schneedecken oder die Vereisung von Seen, beeinträchtigt werden kann. Auch auf Basis von Datensätzen anderer TerraSAR-X Aufnahmemodi (*Spotlight* und *ScanSAR*) und auch von Daten des ALOS-PALSAR konnte bebautes Areal erfasst werden. Um unterschiedliche Charakteristika der Datensätze auszugleichen, waren Anpassungen von Schwellwerten und Ausdehnungen der Schätzfenster erforderlich. Auf den Daten der TerraSAR-X Modi wurden gute Ergebnisse bei der Erfassung bebauter Areale erzielt. Dabei zeichnet sich insbesondere der *ScanSAR*-Modus mit Genauigkeiten zwischen

87,0% und 96,4% aus. Die Übertragung auf PALSAR-Daten kann im Ganzen ebenfalls als gelungen bezeichnet werden, zeigt sich allerdings mit Gesamtgenauigkeiten bis zu 85,9% weniger robust; verantwortlich dafür ist das unterschiedliche Rückstreuverhalten des L-Band-Radars in Bereichen mit Vegetationsbedeckung. Die von Stasolla und Gamba (2008b) vorgestellte Methodik erweist sich als stabiler und unabhängiger vom verwendeten Frequenzbereich.

Unter Verwendung von TerraSAR-X Daten liegt letztlich mit den hier vorgestellten Methoden ein gutes Werkzeug für Planer und Wissenschaftler zur Erfassung und ersten Beschreibung der aktuellen Ausprägung von Siedlungsräumen und deren Umfeld vor. Die gute Robustheit der Methodik über die Zeit ermöglicht zudem die Bewertung von Veränderungsprozessen in diesen Arealen.

Automatisierbarkeit Neben der guten Übertragbarkeit zeichnen sich die vorgestellten Methoden zur Klassifikation von höchst aufgelösten SAR-Daten durch ein hohes Potential zur Automatisierbarkeit aus. Dieses Potential basiert auf der geringen Komplexität der Methodiken und der hohen Datenqualität, die TerraSAR-X auszeichnet.

Im objektorientierten Ansatz zur Erfassung bebauter Areale ist lediglich die Klassifikation der Daten voll automatisiert möglich. Die Vorverarbeitung der Daten — die Erzeugung eines Texturlayers — konnte nicht in die Prozessroutine integriert werden. Demgegenüber wurden beide pixelbasierten Verfahren derart umgesetzt, dass alle benötigten Rechenschritte, Vorverarbeitung und Klassifikation, in einer Prozessroutine komplett implementiert sind. Die geringen Einbußen in der Qualität der Erfassung bebauter Areale (durchschnittlich 88,5% Gesamtgenauigkeit gegenüber 90,6% objektorientiert) sind, im Hinblick auf eine weitere Operationalisierung, akzeptabel. Da die Erfassung bebauter Areale auf diese Weise ohne weiteres manuelles Eingreifen ermöglicht wird, wurde das Grundprinzip dieses Verfahrens nach Anpassungen am Deutschen Zentrum für Luft- und Raumfahrt (DLR) in der Programmierumgebung C++ umgesetzt und als *Global Urban Footprint* in die Standardprozessroutine der TerraSAR-X/TanDEM-X Datenproduktion implementiert.

Auch im Zuge der Klassifikation der Landbedeckung zeigten sich nur geringe Un-

terschiede in der Klassifikationsgüte der überwachten und der unüberwachten Variante. Die Verbindung von unüberwachter Klassifikation und theoretischer Herleitung der realen Textur (C_T) nach Ulaby et al. (1986a) kann automatisiert umgesetzt werden, da alle hierfür benötigten Informationen in den Meta-Daten eines jeden TerraSAR-X Datensatzes enthalten sind.

Einsatz von TerraSAR-X Daten Abschließend sei an dieser Stelle die hervorragende Eignung von TerraSAR-X Daten zur Nutzung in automatisierten und übertragbaren Prozessoren herausgestellt. Alle entwickelten Klassifikationsansätze basieren alleinig auf der Intensitätsinformation und daraus abgeleiteten Maßen. Diese Möglichkeit wird durch die hervorragende Datenqualität des TerraSAR-X begünstigt. Die Übertragung der Methodik zur Erfassung von bebautem Areal auf Daten des ALOS-PALSAR Sensors zeigt signifikante Abweichungen in der Klassifikationsgüte. Sowohl die Erfassung von bebauten Arealen als auch die Klassifikation einfacher Landbedeckungen können voll operationell mit guter Qualität vorgenommen werden. Zudem kann, wie gezeigt wurde, durch die Anwendung individueller Klassifikationsparameter die Genauigkeit, sollte dies erforderlich werden, noch um einige Prozentpunkte gesteigert werden.

Esch (2006) fasste in seiner Arbeit den Stand der Forschung in der Radarfernerkundung zusammen. Dabei wurde im Hinblick auf die Akzeptanz von Radardaten insbesondere die Notwendigkeit zur 'Entwicklung nutzerorientierter Ansätze zur operationellen Ableitung von Geoinformationsprodukten aus Radaraufnahmen' hervorgehoben. Die Arbeiten der hier vorliegenden Dissertationsschrift fokussierten auf dieser Forderung. Ihr konnte insbesondere im Kontext der Erfassung bebauter Areale, im Einklang mit der in Kapitel 1 gesetzten Zielstellungen, entsprochen werden.

6.2 Ausblick

Die neue Generation von satellitengetragenen Radarsensoren (TerraSAR-X, PALSAR, RADARSAT-2, Cosmo-Skymed) stellt eine große Bandbreite von SAR-Daten zur Verfügung, deren Anwendungsmöglichkeiten noch nicht voll ausgeschöpft sind. In

der hier vorgestellten Arbeit konnten einige Methoden zur Nutzung von TerraSAR-X und ALOS-PALSAR Daten vorgestellt werden. Wie diese Methodiken erweitert werden können, um vorhandene Limitierungen zu beseitigen, und welche Potentiale sie noch bieten, soll im Folgenden dargelegt werden.

Erweiterungen Das Potential der vorgestellten pixelbasierten Methodik zur Erfassung bebauter Areale wird derzeit am Deutschen Zentrum für Luft- und Raumfahrt zur automatisierten Erzeugung eines globalen 'Fußabdrucks' urbaner Räume genutzt. Von großem Interesse für Bevölkerungsgeographie, Medizin und Entwicklungshilfe ist die Erfassung von Kleinstsiedlungen in den ländlichen Räumen, insbesondere in Afrika. Die Testgebiete München und Chengdu konnten zwar die Funktionalität der vorgestellten Methodik in ländlichen Räumen gut entwickelter Regionen zeigen. Auf dem afrikanischen Kontinent jedoch machten die Testgebiete Nairobi und Lagos deutlich, dass hier noch weiterer Forschungsbedarf besteht, um kleinere Ansiedlungen in diesen Regionen mit ähnlicher Zuverlässigkeit zu erfassen, wie es mit Städten bereits gelungen ist. He et al. (2006) eliminieren über eine Adaption der Schätzfenster Einschlussfehler im Bereich von Bergkämmen. Über eine ähnliche Vorgehensweise, der Anpassung der Schätzfenster im Bereich ländlicher Regionen in Afrika, könnte es gelingen die weiträumig verteilten kleineren Hüttenstrukturen besser zu fassen. Allerdings kann auf diese Weise auch der Einschlussfehler erhöht werden, da auch natürliche Strukturen wie freistehende Felsen und kleinere Baugruppen ein ähnliches Erscheinungsbild im X-Band erzeugen können. Im Zuge dieser Arbeiten konnten diesbezüglich keine Tests vorgenommen werden, da entsprechende Referenzdaten fehlten. Letztlich dürften aber Verbesserungen der Klassifikationsgüte in diesen Arealen nur mit erhöhtem Aufwand zu erreichen sein, was wiederum zu höheren Rechenzeiten führt. Dennoch wäre der Nutzen einer akkuraten Erfassung solcher Ansiedlungen wäre jedoch sehr groß.

Häufig sind Einschlussfehler bei der Erfassung von bebauten Arealen im Bereich von Bergkämmen zu finden, da diese Bereiche hohe Texturwerte zeigen. Dies ist auf die hohe Intensität auf der einen Seite des Kamms und der niedrigen Intensität auf der anderen Seite zurückzuführen. Wie im Kontext der Erfassung kleinerer Siedlungsstrukturen auf dem afrikanischen Kontinent, könnte hier die Vorgehensweise von He

et al. (2006) eine Verbesserung der Klassifikation bewirken; die Autoren konnten in ihren Arbeiten diese Fehlerquelle über die adaptive und iterative Anpassung der Schätzfenster weitestgehend ausschalten.

Die Übertragung der Methodik zur Erfassung bebauter Areale auf Datensätze des PALSAR Sensors zeigte erhebliche Schwächen, die weitestgehend auf das Rückstreuverhalten im L-Band zurückzuführen sind (vgl. Abschnitt 5.2.5). Die Methodik ist, in der vorgestellten Form, auf X-Band SAR spezialisiert. Auch wenn mit TanDEM-X eine weltweite Abdeckung mit Daten garantiert ist, lohnt es sich auf lange Sicht, eine verstärkte Anpassung der Methode auf andere Radarbänder voranzutreiben, wie dies bereits Stasolla und Gamba (2008b) gelungen ist. Langfristig könnte somit ein SAR-basiertes Monitoring der Siedlungsräume nach vergleichsweise einheitlichen Kriterien gewährleistet werden. Diesbezüglich ist auch die Anwendung auf das R-Band des kanadischen Radarsat von großem Interesse.

Tests zur zeitlichen Übertragbarkeit auf drei Testgebieten konnte die hervorragende Eignung des pixelbasierten Verfahrens zur Erfassung bebauter Areale im Hinblick auf ein Siedlungsmonitoring zeigen. Die Gesamtgenauigkeiten der Klassifikationen schwanken für jedes Testgebiete um lediglich zwei Prozent. Zwischen 3% und 8,7% der jeweiligen Gesamtfläche weisen Veränderungen auf, die durch Fehlinterpretationen hervorgerufen wurden. In geringem Maße waren diese auf die Verwendung unterschiedlicher Aufnahmegeometrien zurückzuführen. Eine stärkere Generalisierung der erstellten Siedlungsmasken, beispielsweise durch Beschneiden der Randlagen, könnte diese Schwankungen beseitigen, .

Potentiale Die adäquate Erfassung von Siedlungsräumen an sich und die Beschreibung des Siedlungsumfeldes sind wichtige Schritte hin zur Beobachtung und Bewertung von Ausbreitungstendenzen moderner Städte. Gerade im Hinblick auf die ausufernden und häufig unkontrollierten Erweiterungen der *Megacities* sind solche Informationen sehr wertvoll. Um eine genauere Beschreibung der Siedlungsstrukturen und damit einen Hinweis auf die Nutzung untersuchter Areale zu bekommen, ist eine detailliertere Analyse erforderlich. In Abschnitt 4.4 wurde eine Methode zur Unterscheidung von Baustellen gegenüber anderen Flächen, die eine zeitliche Veränderung

aufzeigen, vorgestellt. Diese Arbeiten sind als Einstieg in die radarbasierte Charakterisierung des Siedlungsraumes zu sehen. Die Arbeiten von Schmidt et al. (2010) und Schmidt et al. (2011) gehen mit der Charakterisierung der Gebäudeanordnung im Siedlungsraum bereits einen wichtigen Schritt weiter. Ein denkbarer nächster Schritt wäre die Abgrenzung von urbanen Strukturtypen aus SAR Daten. Die Verbindung der Gebäudeinformationen von Schmidt et al. (2010) mit deren Verortung innerhalb des Stadtgebietes, die aus den vorliegenden Entwicklungen abgeleitet werden kann, könnte in dieser Hinsicht bereits erste Erfolge bringen.

Im Hinblick auf den Start der *Sentinel*-Mission (Berger und Aschbacher 2012) werden Methoden zur synergetischen Auswertung von SAR-Daten und optischen Daten interessanter. Die im *Sentinel*-Konzept angestrebte Satelliten-Konstellation aus SAR- sowie optischen Sensoren bietet hervorragende Voraussetzungen zur kombinierten Nutzung dieser unterschiedlichen Fernerkundungsdaten (weitere Informationen zu *Sentinel* sind dem Special-Issue *The Sentinel Missions - New Opportunities for Science* des Journals *Remote Sensing of Environment - Volume 120* zu entnehmen). Die hier vorgestellten Methoden zur Erfassung bebauter Areale und zur Beschreibung der Landbedeckung können als Vorklassifikation für weitergehende Analysen auf Basis optischer Daten, wie beispielsweise der Bestimmung der Flächenversiegelung (Esch et al. 2009), dienen.

A

Anhang Daten

Tabelle A.1: Aufnahmeparameter aller verwendeten SAR-Szenen. Die Auflösung bezeichnet die geometrische Auflösung in Entfernung (r) und Azimuth (a). N gibt die *number of looks* in r und a.


Testgebiet	Aufnahme- datum	Polari- sation	mittlerer Einfallswinkel	Auflösung r*a [m]	N r*a
Stripmap					
BUE	15.03.2008	HH	41,1°	2,92*3,10	1,028*1,119
BUE	12.07.2009	VV	21,4°	3,52*3,06	1,021*1,014
CTU	19.04.2008	HH	39,2°	2,92*3,06	1,030*1,103
HYD	09.10.2007	HH	39,2°	3,04*3,00	1,156*1,369
IST	17.07.2007	HH	41,1°	2,93*2,92	1,165*1,443
LOS	07.04.2008	HH	35,3°	3,07*3,07	1,032*1,557
MEX	04.02.2008	HH	28,7°	3,04*3,07	1,031*1,220
MUC	18.07.2007	VV	39,3°	3,04*3,07	1,160*1,369
MUM	03.07.2008	HH	28,8°	3,00*3,05	1,208*1,013
NBO	16.05.2008	VV	39,2°	2,92*3,08	1,035*1,103
PAR	15.08.2008	HH	42,9°	2,99*3,01	1,014*1,170
PAR	14.11.2009	HH	31,1°	3,00*3,04	1,332*1,039
PBE	25.10.2007	HH	37,4°	2,95*2,95	1,033*1,622
PBE	18.02.2010	HH	37,4°	3,01*3,04	1,588*1,039

Fortsetzung nächste Seite ...


... Fortsetzung von letzter Seite					
PBE	25.04.2010	HH	37,4°	3,01*3,04	1,588*1,039
PDG	04.03.2008	HH	28,8°	3,04*2,99	1,054*1,218
PHX	19.02.2008	HH	37,3°	2,92*2,94	1,033*1,622
SYD	13.03.2008	HH	39,2°	2,92*3,15	1,054*1,097
THR	29.04.2008	HH	39,2°	2,92*3,00	1,049*1,097
ScanSAR					
BUE	21.08.2008	HH	36,3°	17,58*17,85	5,422*0,996
IST	24.03.2009	HH	41,9°	16,85*17,66	6,790*0,996
MUC	15.08.2009	HH	40,1°	16,76*17,72	6,546*0,996
SYD	25.03.2008	HH	27,4°	18,17*18,11	0,996*7,924
Spotlight					
CAL	17.06.2008	HH	44,0°	1,73*1,62	1,027*0,995
GAB	28.11.2007	HH	26,0°	1,41*1,20	1,067*1,027
HAR	29.11.2007	HH	33,6°	1,10*1,12	0,995*1,027
KAM	02.12.2007	HH	41,0°	1,00*1,13	0,995*1,170
MUC	17.03.2009	VV	23,0°	1,58*1,36	1,027*1,249
MUC	08.12.2008	VV	23,0°	1,58*1,36	1,027*1,249
MUC	01.02.2009	VV	23,0°	1,58*1,35	1,027*1,249
MUC	23.02.2009	VV	23,0°	1,58*1,36	1,027*1,249
MUC	06.03.2009	VV	23,0°	1,58*1,35	1,027*1,236
MUC	28.03.2009	VV	23,0°	1,58*1,35	1,027*1,249
MUC	08.04.2009	VV	23,0°	1,58*1,36	1,027*1,249
PALSAR					
IST	07.04.2008	HH	34,3°	10*20	1*4
RNR	23.07.2007	HH	34,3°	10*10	1*2

B


Anhang Methoden




Teilabb. B.1(a): Chengdu (CTU)




Teilabb. B.1(b): Hyderabad (HYD)




Teilabb. B.1(c): Istanbul (IST)




Teilabb. B.1(d): Mexico City (MEX)




Teilabb. B.1(e): Nairobi (NBO)



Teilabb. B.1(f): Phoenix (PHX)




Teilabb. B.1(g): Sydney (SYD)




Teilabb. B.1(h): Teheran (THR)

Abbildung B.1: Histogramme der Intensität der Trainingsgebiete zur Landbedeckungsklassifikation CTU (a), HYD (b), IST (c), MEX (d), NBO (e), PHX (f), SYD (g) und THR (h).



Teilabb. B.2(a): Chengdu (CTU)



Teilabb. B.2(b): Hyderabad (HYD)




Abbildung B.2: Histogramme der Textur der Trainingsgebiete zur Landbedeckungsklassifikation CTU (a), HYD (b), IST (c), MEX (d), NBO (e), PHX (f), SYD (g) und THR (h).







Abbildung B.3: Geometrische Effekte in Radaraufnahmen, die auf Grund unterschiedlicher Orientierung von Gebäudeblöcken auftreten. Die schematische Abbildung (oben) zeigt die Aufnahmegeometrie eines Gebäudes in einer Draufsicht. Die Strahlung wird in Abhängigkeit der Gebäudeorientierung zur Blickrichtung (line of sight, LOS) reflektiert. Dementsprechend variiert die zum Sensor hin rückgestreute Energie. An einem Ausschnitt der Stadt Buenos Aires wird ein Beispiel der Auswirkungen dieses Effektes auf eine SAR Szene gegeben. Links die Ausschnitte der TSX-Szene, rechts, zum Vergleich, die Google-Earth® Luftbildaufnahmen der entsprechenden Region.




Anhang Ergebnisse




Teilabb. C.1(a): Chengdu (CTU)




Teilabb. C.1(b): Hyderabad (HYD)




Teilabb. C.1(c): Nairobi (NBO)



Teilabb. C.1(d): Phoenix (PHX)




Teilabb. C.1(e): Sydney (SYD)




Teilabb. C.1(f): Teheran (THR)


Abbildung C.1: Weitere Ergebnisse der objektorientierten Erfassung bebauter Areale für die Testgebiete CTU (a), HYD (b), NBO (c), PHX (d), SYD (e), THR (f). Links sind jeweils die original TSX-Stripmap-Daten zu sehen, rechts die Überlagerung mit der erstellten Siedlungsmaske.



Teilabb. C.2(a): Mumbai (MUM)




Teilabb. C.2(b): Paris (PAR)




Teilabb. C.2(c): Potsdam-Berlin (PBE)


Abbildung C.2: Ergebnisse der pixelbasierten Erfassung bebauter Areale im Zuge der Tests zur räumlichen Übertragbarkeit für die Testgebiete MUM (a), PAR(b) und PBE (c). Links sind jeweils die original TSX-Stripmap-Daten, rechts die Überlagerung mit der erstellten Siedlungsmaske zu sehen.




Teilabb. C.3(a): Potsdam-Berlin (PBE)



Teilabb. C.3(b): Harare (HAR)



Teilabb. C.3(c): Kampala (KAM)



Teilabb. C.3(d): München (MUC)

Abbildung C.3: Ergebnisse der Übertragung der pixelbasierten Erfassung bebauter Areale auf Daten des TSX-SL-HR Modus für die Testgebiete GAB (a), HAR (b), KAM (c), MUC (d). Oben sind jeweils die original TSX-SL-HR Daten, rechts die Überlagerung mit der erstellten Siedlungsmaske zu sehen.







Abbildung C.4: Histogramme der Intensität der vier Untersuchungsräume zur Landbedeckungsklassifikation BUE (a), LOS (b), MUC (c) und PDG (d).




Teilabb. C.5(a): Buenos Aires (BUE)



Teilabb. C.5(b): Lagos (LOS)



Teilabb. C.5(c): München (MUC)




Teilabb. C.5(d): Padang (PDG)


Abbildung C.5: Histogramme der Textur der vier Untersuchungsräume zur Landbedeckungsklassifikation BUE (a), LOS (b), MUC (c) und PDG (d).

Tabelle C.1: Hersteller- (HG) und Nutzergüte (NG) der Landbedeckungsklassifikationen für die vier Testgebiete Buenos Aires (BUE), Lagos (LOS), München (MUC) sowie Padang (PDG). Alle Werte in [%].


	Stadt		Wald		Offenland		Wasser	
	HG	NG	HG	NG	HG	NG	HG	NG
BUE								
unüberwacht theoretisch	95,6	77,7	39,7	46,3	65,0	85,1	100	94,6
überwacht theoretisch	95,4	73,1	36,8	58,2	71,3	76,6	98,4	97,7
unüberwacht automatisch	93,0	81,2	44,2	50,8	69,0	83,2	100	94,6
überwacht automatisch	95,4	73,1	36,8	58,2	71,3	76,6	98,4	97,7
LOS								
unüberwacht theoretisch	87,9	68,5	67,7	93,1	71,4	31,9	100	95,4
überwacht theoretisch	89,4	67,8	74,1	82,7	43,5	63,8	100	95,4
unüberwacht automatisch	89,8	65,1	67,4	86,1	50,0	48,9	100	92,6
überwacht automatisch	95,7	84,9	38,5	35,8	40,3	69,1	94,7	98,4
MUC								
unüberwacht theoretisch	92,4	87,2	64,8	57,7	71,8	87,3	94,2	92,6
überwacht theoretisch	87,8	81,8	71,2	65,0	80,6	85,3	95,6	89,3
unüberwacht automatisch	92,5	88,3	68,5	62,5	74,2	87,3	94,2	92,6
überwacht automatisch	87,8	91,8	71,2	65,0	80,6	85,3	95,6	89,3
PDG								
unüberwacht theoretisch	95,7	91,7	53,8	71,4	25,8	40,5	98,9	71,1
überwacht theoretisch	94,8	90,5	39,5	24,3	41,6	76,2	95,5	98,4
unüberwacht automatisch	96,2	86,4	46,7	60,0	30,6	61,9	98,9	71,1
überwacht automatisch	95,7	84,9	38,5	35,8	40,3	69,1	94,7	98,4



Teilabb. C.6(a): Buenos Aires (BUE)



Teilabb. C.6(b): Lagos (LOS)



Teilabb. C.6(c): Padang (PDG)

Abbildung C.6: Landbedeckungsklassifikation auf Daten des TSX-*Stripmap* Modus für die Testgebiete BUE (a), LOS (b) und PDG (c). Links sind jeweils die original TSX-*Stripmap*-Daten, rechts die Überlagerung mit der Klassifikation zu sehen.

Abkürzungsverzeichnis

a Azimuth	GEC <i>Geocoded ellipsoid corrected</i>
A Amplitudeninformation	GLCM Grauwert-Kookurrenz-Matrix
ACD <i>Amplitude Change Detection</i>	GPS <i>Global positioning system</i>
AIRSAR <i>Airborne SAR</i>	GUA <i>groupe urban area</i> (Sammelklasse)
ALOS <i>Advanced Land Observation Satellite</i>	GUF <i>groupe urban footprint</i> (Sammelklasse)
ASM GLCM Texturmaß 'angular second moment	GUS <i>groupe urban scatterer</i> (Sammelklasse)
BMWi Bundesministerium für Wirtschaft und Technologie	H Horizontal polarisiert
BUE Buenos Aires (Testgebiet)	HG Herstellergenauigkeit
CCD <i>Coherent Change Detection</i>	HH Gesendete und empfangene Strahlung horizontal polarisiert
CON GLCM Texturmaß Kontrast	HOM GLCM Texturmaß Homogenität
COR GLCM Texturmaß Korrelation	HYD Hyderabad (Testgebiet)
CTU Chengdu (Testgebiet)	I Intensität
DBC <i>Distinct backscattering center</i> , starke Rückstreuer (Klasse)	IEEE <i>Institute of Electrical and Electronics Engineers</i>
DIS GLCM Texturmaß Unterschiedlichkeit	InSAR Interferometrisches SAR
DLR Deutsches Zentrum- für Luft- und Raumfahrt	IST Istanbul (Testgebiet)
E-SAR <i>Experrimental Airborne SAR</i>	ITD Infoterra GmbH
EBU <i>enclosed by urban</i> (Klasse)	JAXA <i>Japan Aerospace Exploration Agency</i>
EEC <i>Enhanced Ellipsoid Corrected</i>	JERS-1 <i>Japanese Earth Resources Satellite</i>
EMS Elektromagnetische Strahlung	KBA Kein bebautes Areal (Klasse)
ENT GLCM Texturmaß Entropie	LIDAR <i>Light Detection and Ranging</i>
EOC <i>Error of commission</i>	LOS Lagos (Testgebiet)
ERS <i>European Remote Sensing Satellite</i>	MAX Maximum

MDA <i>Mean Decrease in Accuracy</i>	SC <i>ScanSAR</i> (Aufnahmemodus)
MEAN Mittelwert	SIR <i>Shuttle Interferometric Radar</i>
MED Median	SL <i>Spotlight</i> (Aufnahmemodus)
MEX Mexiko City (Testgebiet)	SL-HR <i>Spotlight-High-Resolution</i> (Aufnahmemodus)
MGD <i>Multilook ground range detected</i>	SM <i>Stripmap</i> (Aufnahmemodus)
MIN Minimum	SNR Signal-Rausch-Verhältnis
MUC München (Testgebiet)	SPOT <i>Système Probatoire d’Observation de la Terre</i>
NBA Nicht bebautes Areal (Klasse)	SSC <i>Single-look slant-range complex</i>
NBO Nairobi (Testgebiet)	STD Standardabweichung
NG Nutzergenauigkeit	T Schwellwert (<i>threshold</i>)
NIR Nahes Infrarot	TDX TanDEM-X
O Objekt	TGRS <i>Transactions on Geoscience and Remote Sensing</i>
p Bildelement (Pixel)	THR Teheran (Testgebiet)
P-Matrix Wahrscheinlichkeitsmatrix	TSX TerraSAR-X
PALSAR <i>Phased Array type L-band SAR</i>	UA Urbanes Areal (Klasse)
PAR Paris (Testgebiet)	UN Vereinte Nationen
PBA Potentiell bebautes Areal (Klasse)	UST Urbane Strukturtypen
PBE Potsdam-Berlin (Testgebiet)	V Vertikal polarisiert
PDG Padang (Testgebiet)	VAR GLCM Texturmaß Varianz
PUS <i>Potential urban structure</i> (Klasse)	VV Gesendete und empfangene Strahlung vertikal polarisiert
r Entfernung	w Fenster im <i>moving-window</i> -Ansatz; Wichtungparameter
Radar <i>Radio detection and ranging</i>	
RAR Radar mit realer Apertur	
RNR Rhein-Neckar-Region (Testgebiet)	
SAR Radar mit synthetischer Apertur	

Literaturverzeichnis

- Ainsworth, T. L., Schuler, D. L. und Lee, J.-S.** (2008). Polarimetric SAR characterization of man-made structures in urban areas using normalized circular-pol correlation coefficients. *Remote Sensing of Environment* **112**, 2876–2885.
- Albertz, J.** (2001). *Einführung in die Fernerkundung - Grundlagen der Interpretation von Luft- und Satellitenbildern*. Darmstadt: Wissenschaftliche Buchgesellschaft, 2. Auflage, 250 Seiten. ISBN: 3-534-14624-7.
- ASI** (2007). *COSMO-SkyMed Mission - COSMO-SkyMed System Description & User Guide*. 03.03.2010.
- ASI** (2012). COSMO-SkyMed Web Site. <http://www.cosmo-skymed.it/en/index.htm>. Letzter Zugriff: 13.06.2012.
- Baatz, M. und Schäpe, A.** (2001). Multiresolution Segmentation - an optimization approach for high quality multi-scale segmentation. In J. Strobl, T. Blaschke und G. Griesebner, Eds., *Angewandte Geographische Informationsverarbeitung*, Beiträge zum AGIT-Symposium XII. Karlsruhe: Herbert Wichmann Verlag. ISBN-13: 978-3-8790-7361-0.
- Bachmann, M., Schwerdt, M. und Bräutigam, B.** (2010). TerraSAR-X antenna calibration and monitoring based on a precise antenna model. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 690–701.
- Banzhaf, E. und Höfer, R.** (2008). Monitoring urban structure types as spatial indicators with CIR arial photographs for a more effective urban environmental management. *IEEE Journal of selected Topics in Applied Earth Observations and Remote Sensing* **1**, 129–138.
- Baraldi, A. und Parmiggiani, F.** (1995). An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Geoscience and Remote Sensing* **33**, 293–304.
- Berger, M. und Aschbacher, J.** (2012). Preface: The Sentinel missions - new opportunities for science. *Remote Sensing of Environment* **120**, 1–2.

- Bähr, H.-P.** (2005). Ein Gerüst der Bildanalyse. In H.-P. Bähr und T. Vögtle, Eds., *Digitale Bildverarbeitung - Anwendungen in Photogrammetrie, Fernerkundung und GIS*. Heidelberg: Herbert Wichmann Verlag, 4. Auflage, Seiten 81–105.
- Breiman, L.** (1996). Bagging predictors. *Machine Learning* **24**, 123–140.
- Breiman, L.** (2001). Random forests. *Machine Learning* **45**, 5–32.
- Breiman, L. und Cutler, A.** (2004). *Random forests. The Random Forests User's Manual*. Letzter Zugriff: 19.09.2011.
- Breit, H., Fritz, T., Balss, U., Lachaise, M., Niedermeier, A. und Vonavka, M.** (2010). TerraSAR-X SAR processing and products. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 727–740.
- Bräutigam, B., Gonzalez, J. H., Schwerdt, M. und Bachmann, M.** (2010). TerraSAR-X instrument calibration results and extension for TanDEM-X. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 702–715.
- Bruzzone, L., Marconcini, M., Wegmüller, U. und Wiesmann, A.** (2004). An advanced system for the automatic classification of multitemporal SAR images. *IEEE Transactions on Geoscience and Remote Sensing* **42**, 1321–1334.
- Buckreuss, S. und Schättler, B.** (2010). The TerraSAR-X ground segment. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 623–632.
- Candès, E. J. und Donoho, D. L.** (1999). Curvelets - a surprisingly effective nonadaptive representation for objects with edges. In A. Cohen, C. Rabut und L. Schumaker, Eds., *Curve and Surface Fitting: Saint-Malo 1999 (Innovations in Applied Mathematics)*. Nashville, USA: Vanderbilt University Press.
- Canty, M. J.** (2007). *Image Analysis, Classification and Change Detection in Remote Sensing*. Boca Raton: CRC Press, 348 Seiten. ISBN-13: 978-0-8493-7251-3.
- Clausi, D.** (2002). An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of Remote Sensing* **28**, 45–62.

- Clinton, N., Holt, A., Yan, L. und Gong, P.** (2008). An accuracy assessment measure for object based image segmentation. In *Proceedings of ISPRS 2008*, Band XXXVII. ISPRS.
- Congalton, R. G.** (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment* **37**, 35–46.
- Corbane, C., Faure, J.-F., Baghdadi, N., Villeneuve, N. und Petit, M.** (2008). Rapid urban mapping using SAR/optical imagery synergy. *Sensors* **8**, 7125–7142.
- Definiens** (2007). *Definiens Developer 7 - Reference Book*.
- Definiens** (2008). *Definiens Developer 7 - User Guide*.
- Dekker, R.** (2005). SAR change detection techniques and applications. In *Global Development in Environmental Earth Observation from Space - Proceedings of 25th EARSeL Symposium*. Millpress Science Publisher.
- Dell’Acqua, F. und Gamba, P.** (2010). *Rapid Mapping Using Airborne and Satellite SAR Images*, Kapitel 2. Remote Sensing and Digital Image Processing. Dordrecht: Springer Verlag, Seiten 49–68.
- Dell’Acqua, F., Gamba, P. und Lisini, G.** (2009). Rapid mapping of high resolution sar scenes. *ISPRS Journal of Photogrammetry and Remote Sensing* **64**, 482–489.
- Derrode, S., Mercier, G. und Pieczynski, W.** (2003). Unsupervised change detection in SAR images using a multicomponent HMC model. In P. Smits und L. Bruzzone, Eds., *Analysis of Multi-Temporal Remote Sensing Images: Proceedings of the Multitemp 2003*, Nummer 2 in Series in Remote Sensing. Singapur: World Scientific Publishing,. ISBN: 981-238-915-6.
- DLR** (2011). DLR - Raumfahrtmanagement - TanDEM-X. http://www.dlr.de/rd/desktopdefault.aspx/tabid-2440/3586_read-16692/. Letzter Zugriff: 11.05.2011.

- Donnay, J.-P., Barnsley, M. J. und Longley, P. A.**, Eds. (2001). *Remote Sensing and Urban Analysis*. GISDATA 9. London: Taylor & Francis, 192 Seiten. ISBN: 0-7484-0860-6.
- Ehlers, M.** (2007). New developments and trends for urban remote sensing. In Q. Weng und D. A. Quattrochi, Eds., *Urban Remote Sensing*, Kapitel 17. Boca Raton, FL: CRC Press, Seiten 357–375.
- Esch, T.** (2006). *Automatisierte Analyse von Siedlungsflächen auf der Basis höchstauflösender Radardaten*. Doktorarbeit, Universität Würzburg.
- Esch, T., Himmler, V., Schorcht, G., Thiel, M., Wehrmann, T., Bachofer, F., Conrad, C., Schmidt, M. und Dech, S.** (2009). Large-area assessment of impervious surface based on integrated analysis of single-date landsat-7 images and geospatial vector data. *Remote Sensing of Environment* **113**, 1678–1690.
- Esch, T., Roth, A., Thiel, M., Schmidt, M. und Dech, S.** (2008a). Comparison of ALOS-PALSAR and TerraSAR-X data in terms of detecting settlements - first results. In *ALOS-Symposium 2008*.
- Esch, T., Schenk, A., Ullmann, T., Thiel, M., Roth, A. und Dech, S.** (2011). Characterization of land cover types in TerraSAR-X images by combined analysis of speckle statistics and intensity information. *IEEE Transactions on Geoscience and Remote Sensing* **49**, 1911–1925.
- Esch, T., Thiel, M., Bock, M., Roth, A. und Dech, S.** (2008b). Improvement of image segmentation accuracy based on multiscale optimization procedure. *IEEE Geoscience and Remote Sensing Letters* **5**, 463–467.
- Esch, T., Thiel, M., Schenk, A., Roth, A., Müller, A. und Dech, S.** (2010). Delineation of urban footprints from TerraSAR-X data by analyzing speckle characteristics and intensity information. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 905–916.
- Fornaro, G., Lombardini, F. und Serafino, F.** (2005). Three-dimensional multi-pass sar focusing: Experiments with long-term spaceborne data. *IEEE Transactions on Geoscience and Remote Sensing* **43**, 702–714.

- Frate, F. D., Pacifici, F. und Solimini, D.** (2008). Monitoring urban land cover in Rome, Italy, and its changes by single-polarization multitemporal SAR images. *IEEE Journal of selected Topics in Applied Earth Observations and Remote Sensing* **1**, 87–97.
- Fritz, T. und Eineder, M.** (2008). Ground segment basic product specification document. TX-GS-DD-3302 v1.3, TerraSAR-X Ground Segment.
- Frulla, L. A., Milovich, J. A. und Gagliardini, D. A.** (2000). Automatic computation of speckle standard deviation in SAR images. *International Journal of Remote Sensing* **21**, 2883–2899.
- Gaebe, W.** (2004). *Urbane Räume*. Stuttgart: UB, 352 Seiten. ISBN: 3-8252-2511-9.
- Gamba, P., Tupin, F. und Weng, Q.** (2008). Introduction to the issue on remote sensing of human settlements: Status and challenges. *IEEE Journal of selected Topics in Applied Earth Observations and Remote Sensing* **1**, 82–86.
- Gierull, C. H. und Sikaneta, I. C.** (2002). Estimating the effective number of looks in interferometric SAR data. *IEEE Transactions on Geoscience and Remote Sensing* **40**, 1733–1742.
- Gonzalez, R. C. und Woods, R. E.** (2002). *Digital Image Processing*. New Jersey: Prentice-Hall, Inc., 793 Seiten. ISBN: 0-201-18075-8.
- Goodman, J.** (1976). Some fundamental properties of speckle. *Journal of the Optical Society of America* **66**, 1145–1150.
- Gouinaud, C. und Tupin, F.** (1996). Potential and use of radar images for characterization and detection of urban areas. In *Proceedings of IGARSS*, Band 1.
- Grey, W. M. F., Luckman, A. J. und Holland, D.** (2003). Mapping urban change in the UK using satellite radar interferometry. *Remote Sensing of Environment* **87**, 16–22.
- Gu, J., Chen, J., Zhou, Q., Zhang, H. und Ma, L.** (2008). Quantitative textural parameter selection for residential extraction from high-resolution remotely sensed imagery. In *Proceedings IAPRS 2008*, Band XXXVII. ISPRS.

- Guida, R., Iodice, A., Riccio, D. und Stilla, U.** (2008). Model-based interpretation of high-resolution SAR images of buildings. *IEEE Journal of selected Topics in Applied Earth Observations and Remote Sensing* **1**, 107–119.
- Hall-Beyer, M.** (2007). The GLCM Tutorial Home Page. <http://www.fp.ucalgary.ca/mhallbey/tutorial.htm>. Letzter Zugriff: 17.08.2011.
- Halliday, D., Resnick, R. und Walker, J.** (2003). *Physik*. Weinheim, D: Wiley-VCH, 1388 Seiten. ISBN: 3-527-40366-3.
- Hanssen, R. F.** (2001). *Radar Interferometry - Data Interpretation and Error Analysis*. Remote Sensing and Digital Image Processing. Dordrecht, NL: Kluwer Academic Publishers, 308 Seiten. ISBN: 0-7923-6945-9.
- Haralick, R.** (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE* **67**, 786–804.
- Haralick, R. M., Shanmugam, K. und Dinstein, I.** (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics* **SMC-3**, 610–621.
- He, C., Xiy, G.-S. und Sun, H.** (2006). An adaptive and iterative method of urban area extraction from SAR images. *IEEE Geoscience and Remote Sensing Letters* **3**, 504–507.
- Hein, A.** (2004). *Processing of SAR Data; Fundamentals, Signal Processing, Interferometry*. Berlin: Springer Verlag, 1. Auflage, 291 Seiten. ISBN-13: 978-3-5400-5043-8.
- Heineberg, H.** (2006). *Stadtgeographie*. Paderborn: F. Schöningh, 3. Auflage, 480 Seiten. ISBN-13: 978-3-8252-2199-9.
- Helbig, A. und Schirmer, J.** (1999). Einleitung. In A. Helbig, J. Baumüller und M. Kerschgens, Eds., *Stadtklima und Luftreinhaltung*, Kapitel 1. Springer Verlag, 2. Auflage, Seiten 1–3.
- Henderson, F. und Xia, Z.-G.** (1997). SAR applications in human settlement detection, population estimation and urban land use pattern analysis: A status report. *IEEE Transactions on Geoscience and Remote Sensing* **35**, 79–85.

- Henderson, F. M. und Lewis, A. J.**, Eds. (1998). *Principles & Applications of Imaging Radar*, Band 2 von *Manual of Remote Sensing*. New York: John Wiley & Sons, Inc., 3. Auflage, 929 Seiten. ISBN: 0-471-29406-3.
- Henderson, F. M. und Xia, Z.-G.** (1998). Radar applications in urban analysis, settlement detection and population estimation. In F. M. Henderson und A. J. Lewis, Eds., *Principles & Applications of Imaging Radar*, Band 2 von *Manual of Remote Sensing*, Kapitel 15. New York: John Wiley & Sons, Inc., 3. Auflage, Seiten 733–768.
- Herold, N. D., Haack, B. N. und Solomon, E.** (2005). Radar spatial considerations for land cover extraction. *International Journal of Remote Sensing* **26**, 1383–1401.
- Hostert, P.** (2007). Advances in urban remote sensing: Examples from Berlin (Germany). In M. Netzband, W. L. Stefanov und C. Redman, Eds., *Applied Remote Sensing for Urban Planning, Governance and Sustainability*, Kapitel 3. Berlin: Springer Verlag, Seiten 37–51.
- Hu, D.-Y., Li, X.-J., Zhao, W.-J. und Gong, H.-L.** (2008). Texture analysis and its application for single-band SAR thematic information extraction. In *Geoscience and Remote Sensing Symposium (IGARSS), Boston*. IEEE International.
- Hueso González, J., Bachmann, M., Krieger, G. und Fiedler, H.** (2010). Development of the TanDEM-X calibration concept: Analysis of systematic errors. *IEEE Transaction on Geoscience and Remote Sensing* **48**, 716–726.
- JAXA** (2008). *ALOS Data Users Handbook*.
- JAXA** (2009). *ALOS/PALSAR Level 1.1/1.5 product format description*. Stand: 16.03.2010.
- Jensen, J. R.** (2000). *Remote Sensing of the Environment: An Earth Resource Perspective*. Prentice-Hall Series in Geographic Information Science. Upper Saddle River, NJ: Prentice-Hall, Inc., 544 Seiten. ISBN: 0-13-489733-1.
- Jähne, B.** (2002). *Digitale Bildverarbeitung*. Berlin: Springer Verlag, 5. Auflage, 618 Seiten. ISBN: 3-540-41260-3.

- Klausing, H. und Holpp, W.**, Eds. (2000). *Radar mit realer und synthetischer Apertur - Konzeption und Realisierung*. München: Oldenbourg Wissenschaftsverlag GmbH, 399 Seiten. ISBN: 3-486-23475-7.
- Liao, M. S., Jiang, L. M., Lin, H. und Li, D.** (2005). Urban change detection using coherence and intensity characteristics of multi-temporal ERS-1/2 imagery. In *Proceedings of SPIE, Image Signal Processing and Remote Sensing*, Band 5982. SPIE.
- Lichtenberger, E.** (1998). *Stadtgeographie*, Band 1 von *Teubner Studienbücher der Geographie*. Stuttgart: B. G. Teubner, 3. Auflage. ISBN: 3-519-23424-6.
- Lillesand, T. M. und Kiefer, R. W.** (1994). *Remote Sensing and Image Interpretation*. New York: John Wiley & Sons, Inc., 3. Auflage, 750 Seiten. ISBN: 0-471-57783-9.
- Lisini, G., Dell'Acqua und Gamba, P.** (2008). Rapid land mapping by TerraSAR-X VHR data. *Proceedings of IGARSS 2008* , II-383 – II-386.
- Lisini, G. und Gamba, P.** (2008). Mapping urban area extents with TerraSAR-X singlepolarization images. *3. TerraSAR-X Science Team Meeting* , 5.
- Maillard, P.** (2003). Comparing texture analysis methods through classification. *Photogrammetric Engineering & Remote Sensing* **69**, 357–367.
- Mejail, M., Jacobo-Berlles, J., Frery, A. und Bustos, O.** (2003). Classification of SAR images using a general and tractable multiplicative model. *International Journal of Remote Sensing* **24**, 3565–3582.
- Michaelson, E., Soergel, U. und Thoennessen, U.** (2005). Potential of building extraction from multi-aspect high-resolution amplitude SAR data. In U. Stilla, F. Rottensteiner und S. Hinz, Eds., *CMRT05*, Band XXXVI. IAPRS.
- Miller, R. B. und Small, C.** (2003). Cities from space: potential applications of remote sensing in urban environmental research and policy. *Environmental Science & Policy* **6**, 129–137.

- Mittermayer, J., Schättler, B. und Younis, M.** (2010a). TerraSAR-X commissioning phase execution summary. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 649–659.
- Mittermayer, J., Younis, M., Metzger, R., Wollstadt, S., Martínez, J. M. und Meta, A.** (2010b). TerraSAR-X system performance characterization and verification. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 660–676.
- Moreira, A. und Bamler, R.** (2010). Foreword to the special issue on TerraSAR-X: Mission, calibration, and first results. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 603–604.
- Nascimento, A. D. C., Cintra, R. J. und Frery, A. C.** (2010). Hypothesis testing in speckle data with stochastic distances. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 373–385.
- Ndi Nyoungui, A., Tonye, E. und Akono, A.** (2002). Evaluation of speckle filtering and texture analysis methods for land cover classification from SAR images. *International Journal of Remote Sensing* **23**, 1895–1925.
- Netzband, M., Stefanov, W. L. und Redman, C., Eds.** (2007). *Applied Remote Sensing for Urban Planning, Governance and Sustainability*. Berlin: Springer Verlag, 278 Seiten. ISBN-13: 978-3-540-25546-8.
- Oliver, C. und Quegan, S.** (2004). *Understanding Synthetic Aperture Radar Images*. Scitech Publishing Inc., 479 Seiten. ISBN-13: 978-1-8911-2131-9.
- Paesler, R.** (2008). *Stadtgeographie*. Geowissen Kompakt. Darmstadt: Wissenschaftliche Buchgesellschaft, 136 Seiten. ISBN-13: 978-3-534-15629-0.
- Pauleit, S. und Duhme, F.** (2000). Assessing the environmental performance of land cover types for urban planning. *Landscape and Urban Planning* **52**, 1 – 20.
- Pellizzeri, T. M.** (2003). Classification of polarimetric SAR images of suburban areas using joint annealed segmentation and 'H/A/a' polarimetric decomposition. *ISPRS Journal of Photogrammetry & Remote Sensing* **58**, 55 – 70.

- Pesaresi, M., Gerhardinger, A. und Kayitakire, F.** (2007). Monitoring settlement dynamics by anisotropic textural analysis of panchromatic VHR data. In *Proceedings of Joint Remote Sensing Event*. IEEE.
- Pfletschinger, P.** (2010). *Einsatz von Texturmaßen zur Erfassung von Baustellen aus höchstauflösenden SAR-Daten*. Diplomarbeit, Universität Würzburg.
- Pitz, W. und Miller, D.** (2010). The TerraSAR-X satellite. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 615–622.
- Rajesh, K., Jawahar, C., Sengupta, S. und Sinha, S.** (2001). Performance analysis of texture features for characterization and classification of SAR images. *International Journal of Remote Sensing* **22**, 1555–1569.
- Rashed, T. und Jürgens, C., Eds.** (2010). *Remote Sensing of Urban and Suburban Areas*. Remote Sensing and Digital Image Processing. Dordrecht: Springer Verlag, 1. Auflage, 352 Seiten. ISBN-13: 978-1-4020-4371-0.
- Reigber, A. und Moreira, A.** (2000). First demonstration of airborne SAR tomography using multibaseline L-band data. *IEEE Transactions on Geoscience and Remote Sensing* **38**, 2142–2152.
- Richards, J. A.** (2009). *Remote Sensing with Imaging Radar*. Signals and Communication Technology. Berlin: Springer Verlag, 361 Seiten. ISBN-13: 978-3-6420-2019-3.
- Richards, J. A. und Jia, X.** (1999). *Remote Sensing Digital Image Analysis*. Berlin: Springer Verlag, 3. Auflage, 363 Seiten. ISBN: 3-540-64860-7.
- Riedel, T., Thiel, C. und Schmullius, C.** (2006). An object-based classification procedure for the derivation of broad land cover classes using optical and SAR data.
- Scheffer, F.** (1998). *Lehrbuch der Bodenkunde*. Stuttgart: Ferdinand Enke Verlag, 14 Auflage, 494 Seiten. ISBN: 3-432-84774-2.
- Scheuchl, B., Ullmann, T. und Koudogbo, F.** (2010). Change detection using high resolution TerraSAR-X data - preliminary results. In W. Wagner und B. Székely, Eds., *Proceedings of ISPRS TC VII Symposium*, Band XXXVIII.

- Schmidt, M., Esch, T., Klein, D. Thiel, M. und Dech, S.** (2010). Estimation of building density using TerraSAR-X-Data. In *Proceedings of the IGARSS*.
- Schmidt, M., Esch, T., Thiel, M. und Dech, S.** (2011). Building detection from single polarized TerraSAR-X Data. In *Proceedings of the SPIE - The international Society for Optical Engineering*.
- Schmitt, A., Wessel, B. und Roth, A.** (2009). Curvelet approach for SAR image denoising, structure enhancement, and change detection. In U. Stilla, F. Rottensteiner und N. Paparoditis, Eds., *Proceedings of IAPRS*, Band XXXVIII.
- Schmitt, A., Wessel, B. und Roth, A.** (2010). Curvelet-based change detection on SAR images for natural disaster mapping. *Photogrammetrie, Fernerkundung, Geoinformation* **6**, 463–474.
- Schwerdt, M., Bräutigam, B., Bachmann, M., Döring, B., Schrank, D. und Gonzalez, J. H.** (2010). Final TerraSAR-X calibration results based on novel efficient methods. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 677–689.
- Soergel, U., Ed.** (2010). *Radar Remote Sensing of Urban Areas*. Remote Sensing and Digital Image Processing. Springer Verlag, 270 Seiten. ISBN-13: 978-9-0481-3750-3.
- Soergel, U., Michaelsen, E., Thoennessen, U. und Stilla, U.** (2005). Potential of high-resolution SAR images for urban analysis. In M. Moeller und E. Wentz, Eds., *Proceedings of ISPRS joint conference (URBAN & URS 2005)*, Band XXXVI. ISPRS WG VIII/1 "Human Settlements and Impact Analysis".
- Stasolla, M. und Gamba, P.** (2008a). Semi-automated extraction of human settlement extent in HR SAR images. In *Proceedings of IGARSS 2008*.
- Stasolla, M. und Gamba, P.** (2008b). Spatial indexes for the extraction of formal and informal human settlements from high-resolution SAR images. *IEEE Journal of selected Topics in Applied Earth Observations and Remote Sensing* **1**, 98–106.

- Steinbrecher, U., Schulze, D., Böer, J. und Mittermayer, J.** (2010). TerraSAR-X instrument operations rooted in the system engineering and calibration project. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 633–641.
- Stilla, U., Soergel, U. und Thoennessen, U.** (2003). Potential and limits of InSAR data for building reconstruction in built-up areas. *ISPRS Journal of Photogrammetry & Remote Sensing* **58**, 113–123.
- Strobl, C.** (2008). *Statistical Issues in Machine Learning - Towards Reliable Split Selection and Variable Importance Measures*. Cuvillier Verlag, 1. Auflage, 204 Seiten. ISBN-13: 978-3-8672-7661-0.
- Strobl, C., Boulesteix, A.-L., Zeileis, A. und Hothorn, T.** (2007). Bias in random forest variable importance measures: illustrations, sources, and a solution. *BMC Bioinformatics* **8**, 1–21.
- Taubenböck, H. und Dech, S.,** Eds. (2010). *Fernerkundung im urbanen Raum - Vom Satellitenbild zur Planungspraxis*. Darmstadt: Wissenschaftliche Buchgesellschaft, 192 Seiten. ISBN-13: 978-3-534-23481-3.
- Thiel, M., Esch, T. und Dech, S.** (2008a). Object-oriented detection of urban areas from TerraSAR-X data. In *EARSeL Joint Workshop SIG Urban Remote Sensing and Radar Remote Sensing*.
- Thiel, M., Esch, T., Wurm, M., Taubenböck, H. und Dech, S.** (2008b). Identification of built-up areas using SAR data - a comparison of TerraSAR-X and ALOS-PALSAR imagery. In *SPIE 2008*.
- Tso, B. und Mather, P. M.** (2001). *Classification Methods for Remotely Sensed Data*. New York: Taylor & Francis, 332 Seiten. ISBN: 0-415-25908-8.
- Tupin, F. und Roux, M.** (2003). Detection of building outlines based on the fusion of SAR and optical features. *ISPRS Journal of Photogrammetry & Remote Sensing* **58**, 71–82.
- Ulaby, F. T., Kouyate, F., Brisco, B. und Williams, T. H. L.** (1986a). Textural information in SAR images. *IEEE Transactions on Geoscience and Remote Sensing* **GE-24**, 235–245.

- Ulaby, F. T., Moore, R. K. und Fung, A. K.** (1981). *Microwave Remote Sensing - Active and Passive*, Band I - Microwave Remote Sensing Fundamentals and Radiometry von *Remote Sensing*. Norwood, MA: Artech House, 456 Seiten. ISBN: 0-8900-6191-2.
- Ulaby, F. T., Moore, R. K. und Fung, A. K.** (1986b). *Microwave Remote Sensing - Active and Passive*, Band III - From Theory to Applications von *Remote Sensing*. Norwood, MA: Artech House, 2162 Seiten. ISBN: 0-89006-192-0.
- Ulaby, F. T., Moore, R. K. und Fung, A. K.** (1986c). *Microwave Remote Sensing - Active and Passive*, Band II - Radar Remote Sensing and Surface Scattering and Emission Theory von *Remote Sensing*. Norwood, MA: Artech House, 1064 Seiten. ISBN-13: 978-0-8900-6191-6.
- Vereinte Nationen** (2011a). United Nations: Development. <http://www.un.org/en/development/index.shtml>. Letzter Zugriff: 13.06.2012.
- Vereinte Nationen** (2011b). World Urbanization Prospects, the 2011 Revision. <http://esa.un.org/unpd/wup/index.htm>. Letzter Zugriff: 15.07.2012.
- Vogel, H.** (1999). *Gerthsen Physik*. Berlin: Springer Verlag, 20. Auflage, 1262 Seiten. ISBN: 3-540-65479-8.
- Weidner, U. und Lemp, D.** (2005). Objektorientierte Klassifikation. In H.-P. Bähr und T. Vögtle, Eds., *Digitale Bildverarbeitung - Anwendungen in Photogrammetrie, Fernerkundung und GIS*. Heidelberg: Herbert Wichmann Verlag, 4. Auflage, Seiten 106–122.
- Weng, Q.**, Ed. (2008). *Remote Sensing of Impervious Surfaces*. Boca Raton, FL: CRC Press, 454 Seiten. ISBN-13: 978-1-4200-4374-7.
- Weng, Q. und Quattrochi, D. A.**, Eds. (2007). *Urban Remote Sensing*. Boca Raton, FL: CRC Press, 412 Seiten. ISBN-13: 978-0-8493-9199-6.
- Werninghaus, R. und Buckreuss, S.** (2010). The TerraSAR-X mission and system design. *IEEE Transactions on Geoscience and Remote Sensing* **48**, 606–614.

- Weydahl, D. J.** (2001). Analysis of ERS SAR coherence images acquired over vegetated areas and urban features. *International Journal of Remote Sensing* **22**, 2811–2830.
- Wurm, M. und Taubenböck, H.** (2010). Fernerkundung als Grundlage zur Identifikation von Stadtstrukturtypen. In H. Taubenböck und S. Dech, Eds., *Fernerkundung im Urbanen Raum*. WBG, Seiten 94–103.
- Xia, Z.-G. und Henderson, F. M.** (1997). Understanding the relationships between radar response patterns and the bio- and geophysical parameters of urban areas. *IEEE Transactions on Geoscience and Remote Sensing* **35**, 93–101.

Eidesstattliche Erklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit mit dem Titel 'Nutzung von Texturinformationen hochaufgelöster SAR-Daten zur Beschreibung von Siedlungsräumen' selbständig und nur unter Verwendung der angegebenen Quellen und Hilfsmittel angefertigt habe.

Würzburg, 13. Februar 2013

Michael Thiel

Lebenslauf

Persönliche Daten

	Michael Thiel
	Diplom - Umweltwissenschaftler
Adresse	Arndtstr. 37 97072 Würzburg
Kontakt	Thiel.Mettendorf@web.de

Letzte Tätigkeiten

seit 09/2012	Wissenschaftlicher Mitarbeiter am Lehrstuhl für Fernerkundung der Universität Würzburg im Projekt 'WASCAL'
08/2011-09/2012	Bearbeitung der eigenen Doktorarbeit Titel der Arbeit: <i>Nutzung von Texturinformationen hochaufgelöster SAR-Daten zur Beschreibung von Siedlungsräumen</i>
11/2006-07/2011	Wissenschaftlicher Mitarbeiter am Lehrstuhl für Fernerkundung der Universität Würzburg Tätigkeiten: <ul style="list-style-type: none">• Mitarbeit im Projekt <i>TerraSAR-X urban</i>• Leitung des Projektes <i>Versiegelung2006</i>• Mitarbeit im Projekt <i>Versiegelung in Bayern</i>• Betreuung von Abschlussarbeiten• Verschiedene Lehrveranstaltungen

Studium

10/1998-08/2006 Studium der Angewandten Umweltwissenschaften, Universität Trier
Hauptfächer: Fernerkundung, Klimatologie
Nebenfächer: Bodenkunde, Hydrologie
Begleitstudium: Raumentwicklung und Landesplanung

Studienbegleitende Tätigkeiten

11/2004-12/2004 Werkstudent am Deutschen Zentrum für Luft- und Raumfahrt (DLR) in Oberpfaffenhofen, Institut für Physik der Atmosphäre
08/2004-10/2004 Praktikum am DLR in Oberpfaffenhofen, Deutsches Fernerkundungsdatenzentrum
01/2000-10/2005 Tätigkeiten als wissenschaftliche Hilfskraft an den Lehrstühlen Hydrologie und Bodenkunde an der Universität Trier

Werdegang vor dem Studium

02/1996-07/1998 Kundenbetreuer, Raiffeisenbank Neuerburg-Land eG
08/1993-01/1996 Ausbildung zum Bankkaufmann, Raiffeisenbank Neuerburg-Land eG

06/1993

Abitur am Staatlichen Eifelgymnasium in Neuerburg
Leistungskurse: Mathematik, Physik, Geschichte

EDV-Kenntnisse

GIS-Software ArcGIS, Erdas Imagine, Envi, eCognition

Programmierung IDL

Betriebssysteme Windows, Linux

Office MS-Office, OpenOffice, L^AT_EX

Sprachkenntnisse

Englisch sehr gut

Französisch Grundkenntnisse

Private Interessen

Sport Laufen (10km, Halbmarathon, Marathon), Fußball, Sportklettern

Sonstiges Geschichte Europas und der Hochkulturen, Städte

Würzburg, 13. Februar 2013

Michael Thiel

Publikationsliste

Peer Reviewed

- Esch, T., Taubenböck, H., Roth, A., Heldens, W., Felbier, A., Thiel, M., Schmidt, M., Müller, A., Dech, S. (2012):** TanDEM-X mission-new perspectives for the inventory and monitoring of global settlement patterns, *Journal of Applied Remote Sensing*, Vol. 6, Issue 1, 061702 (October 04, 2012); doi: 10.1117/1.JRS.6.061702.
- Esch, T., Schenk, A., Ullmann, T., Thiel, M., Roth, A., Dech, S. (2011):** Characterization of Land Cover Types in TerraSAR-S Images by Combined Analysis of Speckle Statistics and Intensity Information, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 49, Issue 6, pp. 1911-1925.
- Esch, T., Thiel, M., Schenk, A., Roth, A., Müller, A., Dech, S. (2010):** Delineation of Urban Footprints From TerraSAR-X Data by Analyzing Speckle Characteristics and Intensity Information, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 48, Issue 2, pp. 905-916.
- Esch, T., Himmler, V., Schorcht, G., Thiel, M., Wehrmann, T., Bachhofer, F., Conrad, C., Schmidt, M., Dech, S. (2009):** Large-area assessment of impervious surface based on integrated analysis of single-date Landsat-7 images and geospatial vector data, *Remote Sensing of Environment*, No. 113, pp. 1678-1690.
- Esch, T., Thiel, M., Bock, M., Roth, A., Dech, S. (2008):** Improvement of Image Segmentation Accuracy based on Multi-Scale Optimization Procedure. *IEEE Geoscience and Remote Sensing Letters*, Vol. 5, No. 3, July 2008.

Konferenzbeiträge

- Firmbach, L., Höfer, R., Thiel, M., Lorz, C. und Weiß, H. (2012):** Analyse der Relevanz der aus Fernerkundungsdaten abgeleiteten urbanen Struktureinheiten für ein integriertes Wasserressourcenmanagement. In: *Proceedings of AGIT 2012*.

Schmidt, M., Esch, T., Thiel, M. und Dech, S. (2011): Building detection from single polarized TerraSAR-X Data. In: Proceedings of the SPIE - The international Society for Optical Engineering.

Esch, T., Schenk, A., Thiel, M., Ullmann, T., Schmidt, M. und Dech, S. (2010): Land cover classification based on single-polarized VHR SAR images using texture information derived via speckle analysis. In: Proceedings of the IGARSS, pp. 1875-1878

Schmidt, M., Esch, T., Klein, D., Thiel, M. und Dech, S. (2010): Estimation of building density using TerraSAR-X-Data. In: Proceedings of the IGARSS, pp. 1936-1939.

Esch, T., Taubenböck, H., Heldens, W., Thiel, M., Wurm, M., Geiss, C. und Dech, S. (2010): Urban remote sensing - how can earth observation support the sustainable development of urban environments? In: Schrenk, M., Popovich, V.V., Engelke, D. und Elisei, P. (Eds.): Proceedings of REAL CORP 2010.

Esch, T., Dech, S. Roth, A., Schmidt, M., Taubenböck, H., Heldens, W., Thiel, M., Wurm, M. und Klein, D. (2009): Monitoring and assessment auf urban environments using space-borne earth observation data. In: Krek, Rumor, Zlatanova und Fendel (Eds.): Urban and Regional Data Management, pp. 385-398.

Klein, D., Esch, T., Himmler, V., Thiel, M. und Dech, S. (2009): Assessment of urban extend and impervious of Cape Town using TerraSAR-X and Landsat images. In: Proceedings of the IGARSS, pp. III-1051 - III-1054.

Thiel, M., Esch, T., Wurm, M., Taubenböck, H., Dech, S. (2008): Identification of built-up areas using SAR data - A comparison of TerraSAR-X and ALOS-PALSAR imagery. In: Proceedings of the SPIE - The international Society for Optical Engineering Vol. 7110.

Taubenböck, H., Esch, T., Wurm, M., Thiel, M., Ullmann, T., Roth, A., Schmidt, M., Mehl, H. und Dech, S. (2008): Urban structure analysis of mega city Mexico City using multi-sensoral remote sensing data. In: Proceedings of the SPIE - The international Society for Optical Engineering Vol. 7110.

Thiel, M., Esch, T., Schenk, A. (2008): Object-oriented detection of urban areas from Terra-SAR-X data. In: Proceedings of ISPRS 2008 Congress, Volume XXXVII, Part B8, Commission VIII, pp. 23-27.

Thiel, M., Esch, T., Dech, S. (2008): Object-oriented detection of settlement

areas from TerraSAR-X data. In: Carsten Jürgens (Ed.), Remote Sensing - New Challenges of High Resolution. Proceedings of the EARSeL Joint Workshop Bochum, March 5th-7th 2008, CD-ROM, pp. 242-248.

Andere

Taubenböck, H. und Thiel, M. (2010): Landbedeckungsklassifikation der Stadt-Umland-Region München und Analyse ihrer raumzeitlichen Entwicklung. Kapitel 4.1, pp. 43-49. In: Taubenböck, H. und Dech, S. (Hrsg.): Fernerkundung im urbanen Raum - Erdbeobachtung auf dem Weg zur Planungspraxis, WBG Darmstadt.

Esch, T., Schorcht, G., Thiel, M. (2007): Satellitengestützte Erfassung der Bodenversiegelung in Bayern. Broschüre des Bayerischen Landesamts für Umwelt (Hrsg.). ISBN-13: 978-3-940009-24-1. Bayerisches Landesamt für Umwelt, Augsburg, 2007. 16 Seiten.

Esch, T., Schorcht, G., Thiel, M. (2007): Satellitengestützte Erfassung der Bodenversiegelung in Bayern. Web-Publikation des Bayerischen Landesamts für Umwelt (Hrsg.). ISBN-13: 978-3-940009-38-8. Bayerisches Landesamt für Umwelt, Augsburg, 2007.